

(19)日本国特許庁 (JP)

(12) 公開特許公報 (A)

(11)特許出願公開番号

特開平9-152886

(43)公開日 平成9年(1997)6月10日

(51)Int.Cl.⁶
G 1 0 L 3/00

識別記号
5 3 5
5 2 1

府内整理番号
F I
G 1 0 L 3/00

5 3 5
5 2 1 F

技術表示箇所

(21)出願番号 特願平7-312286
(22)出願日 平成7年(1995)11月30日

審査請求 有 請求項の数5 O.L (全24頁)

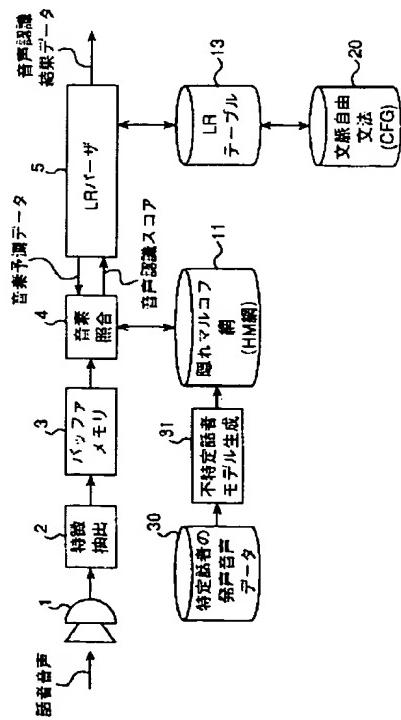
(71)出願人 593118597
株式会社エイ・ティ・アール音声翻訳通信
研究所
京都府相楽郡精華町大字乾谷小字三平谷5
番地
(72)発明者 マリ・オステンドルフ
京都府相楽郡精華町大字乾谷小字三平谷5
番地 株式会社エイ・ティ・アール音声翻
訳通信研究所内
(72)発明者 ハラルド・シンガー
京都府相楽郡精華町大字乾谷小字三平谷5
番地 株式会社エイ・ティ・アール音声翻
訳通信研究所内
(74)代理人 弁理士 青山 葦 (外2名)

(54)【発明の名称】 不特定話者モデル生成装置及び音声認識装置

(57)【要約】

【課題】 従来例に比較して処理装置のメモリ容量の少
なくてすみ、その計算時間を短縮することができる不特
定話者モデル作成装置及び音声認識装置を提供する。

【解決手段】 複数の特定話者の発声音声データに基づ
いて、バーム・ウェルチの学習アルゴリズムを用いて單
一ガウス分布のHMMを生成し、1つの状態をコンテキ
スト方向又は時間方向に分割したときに、最大の尤度の
増加量を有する状態を検索する。次いで、最大の尤度の
増加量を有する状態を、最大の尤度の増加量に対応する
コンテキスト方向又は時間方向に分割した後、バーム・
ウェルチの学習アルゴリズムを用いて单一ガウス分布の
HMMを生成し、上記の処理を、单一ガウス分布のHMM
内の状態を分割することができなくなるまで又は予め
決められた分割数となるまで繰り返すことにより、話者
独立型のHMMを生成する、また、生成された話者独立
型のHMMを用いて音声認識する。



BEST AVAILABLE COPY

【特許請求の範囲】

【請求項1】 複数の特定話者の発聲音声データに基づいて話者独立型の隠れマルコフモデルを生成するモデル生成手段を備えた不特定話者モデル生成装置において、上記モデル生成手段は、複数の特定話者の発聲音声データに基づいて、バーム・ウェルチの学習アルゴリズムを用いて单一ガウス分布の隠れマルコフモデルを生成した後、上記单一ガウス分布の隠れマルコフモデルにおいて、1つの状態をコンテキスト方向又は時間方向に分割したときに、最大の尤度の増加量を有する状態を分割することを繰り返すことにより話者独立型の隠れマルコフモデルを生成することを特徴とする不特定話者モデル生成装置。

【請求項2】 上記モデル生成手段は、複数の特定話者の発聲音声データに基づいて、バーム・ウェルチの学習アルゴリズムを用いて单一ガウス分布の隠れマルコフモデルを生成する初期モデル生成手段と、上記初期モデル生成手段によって生成された单一ガウス分布の隠れマルコフモデルにおいて、1つの状態をコンテキスト方向又は時間方向に分割したときに、最大の尤度の増加量を有する状態を検索する検索手段と、上記検索手段によって検索された最大の尤度の増加量を有する状態を、最大の尤度の増加量に対応するコンテキスト方向又は時間方向に分割した後、バーム・ウェルチの学習アルゴリズムを用いて单一ガウス分布の隠れマルコフモデルを生成する生成手段と、上記生成手段の処理と上記検索手段の処理を、单一ガウス分布の隠れマルコフモデル内の状態を分割することができなくなるまで又は单一ガウス分布の隠れマルコフモデル内の状態数が予め決められた分割数となるまで繰り返すことにより、話者独立型の隠れマルコフモデルを生成する制御手段とを備えたことを特徴とする請求項1記載の不特定話者モデル生成装置。

【請求項3】 上記検索手段によって検索される状態は、直前の処理で上記生成手段によって分割された新しい2つの状態に限定されることを特徴とする請求項2記載の不特定話者モデル生成装置。

【請求項4】 上記検索手段によって検索される状態は、直前の処理で上記生成手段によって分割された新しい2つの状態と、上記新しい2つの状態から距離が1だけ離れた状態とに限定することを特徴とする請求項2記載の不特定話者モデル生成装置。

【請求項5】 入力される発聲音声文の音声信号に基づいて所定の隠れマルコフモデルを参照して音声認識する音声認識手段を備えた音声認識装置において、

上記音声認識手段は、請求項1乃至4のうちの1つに記載の不特定話者モデル生成装置によって生成された話者独立型の隠れマルコフモデルを参照して音声認識することを特徴とする音声認識装置。

【発明の詳細な説明】

【0001】

【発明の属する技術分野】本発明は、複数の特定話者の発聲音声データに基づいて不特定話者の隠れマルコフモデル（以下、HMMという。）を生成する不特定話者モデル生成装置、及び、入力される発聲音声文の音声信号に基づいて当該不特定話者のHMMを参照して音声認識する音声認識装置に関する。

【0002】

【従来の技術】例えば、従来文献1「J. Takami et al., "A successive state splitting algorithm for efficient allophone modeling", Proceedings of the International Conference on Acoustic Speech and Signal Processing, vol. I, pp. 573-576, 1992年」において、従来例の逐次状態分割法（以下、SSS法といふ。）を用いたHMMの生成方法が開示されており、当該SSS法はHMM生成のために有効的な技術であり、最適なHMMのトポロジーを自動的に学習するメカニズムを提供するものである。従来例のSSS法の背景にある基本的発想は、HMMにおける状態を分割するための最も大きな分散を有する状態を選択し、次いでその状態にとって最適な分割方向を採用すれば、HMMの状態ネットワーク（以下、HMM網といふ。）を増大させることができるというものである。この分割を繰り返し適用して得た結果がHMM網であり、特定の単語より小さいのサブワードの単位（例えば音素、モーラ）によるコンテキスト及び時間に対する分散性を効果的に表している。本出願人が行った幾つかの研究においてSSS法は成功裡に使用されており、また他のHMM設計を凌ぐ性能を示している（例えば、従来文献2「A. Nagai et al., "The SSS法-LR Continuous Speech Recognition System: Integrating SSS-Derived Allophone Models and a Phoneme-Context-Dependent LR Parser", Proceedings of International Conference on Spoken Language Processing, pp. 1511-1514, 1992年」、従来文献3「A. Nagai et al., "ATREUS: A Comparative Study of Continuous Speech Recognition Systems at ATR", Proceedings of the International Conference on Acoustic Speech and Signal Processing, vol. II, pp. 139-142, 1993」）。

年)、及び、従来文献4「S. Sagayama et al., "ATREUS:a Speech Recognition Front-end for a Speech Translation System, Proceedings of European Conference on Speech Communication and Technology, pp. 1287-1290, 1993年」(参照。)、
【0003】

【発明が解決しようとする課題】現在実施されているSSS法の不利な点は、これが良好に動作するのが話者依存型データのトポロジーの学習に限定されていることである。話者独立型の学習においては、SSS法によって選択される、最も分散の大きな状態は、調音結合の影響又は時間方向の影響よりもむしろ、話者の分散性をより反映するものと思われる。SSS法を使用して話者独立型のモデルを構築するためには、従来文献5「T. Kosaka et al., "Tree-Structured Speaker Clustering for Speaker-Independent Continuous Speech Recognition", Proceedings of International Conference on Spoken Language Processing, pp. 1375-1378, 1994年」において開示されているように、まず話者依存型のトポロジーを設計し、次いでそれを話者独立型データについて再学習する。この解法は、プロの話者が注意深く読み上げる音声実験では良好に作用する(例えば、従来文献6「J. Takami et al., "Automatic Generation of Speaker-Common Hidden Markov Network by Adding the Speaker Splitting Domain to the Successive State Splitting Algorithm", Proceedings of Acoustic Society in Japan, pp. 155-156, 1992年」(参照。))が、管理の行き届かない状況においては、認識の点で限界があるものと思われる。特に自然に発話する発声音声においては、一人の話者にとって最適なトポロジーが、異なるアクセント、テンポ、スタイルの他の話者には適さない場合もある。

【0004】多くのHMMを用いた音声認識システムに使用されているもので、このSSS法に似た技術としては、時々決定木のコンテキスト方向のモデリングと呼ばれる、分割型分布クラスタリングがある、決定木の設計技術を利用した分布状態の分割型クラスタリングは、例えば、従来文献7「L. R. Bahl et al., "Decision trees for phono-

logical rules in continuous speech", in Proceedings of the International Conference on Acoustic Speech and Signal Processing, pp. 185-188, 1991年)、及び、従来文献8「K.-F. Lee et al., "Allophone Clustering for Continuous Speech Recognition", Proceedings of the International Conference on Acoustic Speech and Signal Processing, pp. 749-752, April 1990年」において全音素のモデルクラスタリング用として最初に提案され、後に連結された混合のための状態レベルのクラスタリング(例えば、従来文献9「X. Huang et al., "An overview of the SPHINX-II speech recognition system", Proceedings of ARPA Workshop on Human Language Technology, pp. 81-86, 1993年」(参照。))、及び、単一ガウス分布へのクラスタリング(例えば、従来文献10「A. Kannan et al., "Maximum Likelihood Clustering of Gaussians for Speech Recognition", IEEE Transactions on Speech and Audio Processing, vol. 2, no. 3, pp. 453-455, 1994年」、従来文献11「S. J. Young et al., "Tree-based state tying for high accuracy acoustic modeling", in Proceedings of ARPA Workshop on Human Language Technology, pp. 307-312, 1994年」、及び、従来文献12「L. Bahl et al., "Context-dependent vector quantization for continuous speech recognition", Proceedings of the International Conference on Acoustic Speech and Signal Processing, vol. II, pp. 632-635, 1993年」(参照。)に拡張されている、これらの方法のアプローチは、ビタビ(Viterbi)のアルゴリズム又は前向き後向きアルゴリズムの何れかを使用して学習の観測データを、予め決定された幾つかのHMMのトポロジーが与えられた状態とを結合させ、次いで学習データの最大尤度に関する目的関数に

基づいてコンテキスト方向の分割のために決定木を成長させている。SSS法とは違い、決定木のコンテキスト方向のモデリングは話者独立型HMMの学習において有効的に利用されている。決定木法とSSS法の両方法間の重大な相違点は、どの分布を分割するかの選択が、SSS法では状態分布の分散の包括的な測定に基づいて行なわれるのに対して、決定木モデリングでは特定のコンテキスト方向の分割に基づいているという点である。

【0005】上述のように、SSS法のアルゴリズムは、図10に示すHM網を連続して成長させる繰り返しアルゴリズムである。HM網の各状態にはそれぞれ、下記の情報が割り当てられている。

(1) 状態番号、(2) 受理可能な異音カテゴリー(音素環境要因の直積空間として定義される)、(3) 先行状態及び後続状態のリスト、(4) 出力確率分布のパラメータ、及び、(5) 自己遷移確率及び後続状態への遷移確率。このHM網に対してある音素サンプルとその音素環境情報が与えられた場合、その音素環境を受理可能な状態を先行及び後続状態リストの制約内で始端から終端まで結ぶ1本の経路を一意に決定することができる。この経路に沿って各状態を連結したものは、図11に示すようなHMMと等価なモデルとなる。従って、経路選択後は通常のHMMと同様に、出力尤度計算やモデルパラメータの推定のためのアルゴリズムをそのまま使用することができる。

【0006】従来例のSSS法では、図12に示すように、まず、2つの混合からどちらがより大きく発散しているかに基づいて分割すべき状態を選択し、次にコンテキスト方向(音素環境方向ともいう)及び時間方向への分割についてテストする。図4はそのトポロジーの変化を図示したものであり、選択された状態がコンテキスト方向及び時間方向に分割される様子を表している。

【0007】従来例のSSS法を用いた話者モデル生成処理を示すフローチャートを図13に示す。図13において、まず、ステップS1で複数の特定話者の発聲音声データに基づいて、公知のバーム・ウェルチの学習アルゴリズムを用いて混合数2の混合ガウス分布のHM網を生成する。次いで、ステップS2で、最大の分散を有する分割すべき状態を検索して決定する。そして、ステップS3で決定された分割すべき状態に対してコンテキスト方向の分割テストと、2個の時間方向の分割テストを実行して、状態を分割するための最良の方向を決定する。さらに、ステップS4では、被影響状態を検索して決定し、L個の被影響状態に対してL個のコンテキスト方向のクラスタリングを実行することにより、各被影響状態に対して新しい混合ガウス分布の初期状態の混合分布パラメータを計算する。次いで、ステップS5では、被影響状態に対してバーム・ウェルチの学習アルゴリズムを用いて混合数2の混合ガウス分布のHM網を生成する。そして、ステップS6で各状態が分割不可能である

か否か又は予め決められた分割数(以下、所定の分割数という。)となったか否かが判断され、分割可能でありかつ所定の分割数に達していないならば、ステップS2に戻って上記の処理を繰り返す。一方、分割できないとき又は所定の分割数に達しているときは、ステップS7で得られたHM網をメモリに格納する。

【0008】「被影響状態」には、音素境界が固定されているものと仮定すれば、この分割によりパラメーターが変化する可能性のあるすべての状態が含まれる。音素境界の存在は、手動でラベル付けされたマーク又はビタビの調整方法を用いて知ることができる。さらに詳細に言えば、被影響状態は、図4が示すように、ネットワークがグミー開始ノード及び終了ノードで切断された後に分割すべき現在の状態に連結される複数の状態のサブネットワーク内のすべての状態である。この定義によれば、より特定的な音素依存サブネットワークが展開されるまで、分割が行われる毎にほとんど全ての状態が影響を受けることになる。コンテキスト方向の分割の場合、コンテキスト依存上のミスマッチによって状態間の幾つかの新規パスが不可能になって取り除かれている場合がある点に注目する必要がある。図4の(b)では、「N」がバスの「取り除き」を示している。

【0009】従来例のSSS法のアルゴリズムにおける主な問題点は、分割すべき最適状態の選択が、実際の分割方向の選択に先立って行われることにある。各状態の出力分布は2つのガウス分布が混合されたものであり、

「最適」状態とは、この2つの混合要素間の離散度が最大のものをいう。但し、こうした混合要素は包括的なものであり、可能な分割とは必ずしも対応していないため、可能な分割に制約があるとすれば、この基準による分割最適状態は事実上の最適な選択とはならない場合がある。例えば、話者独立型HMMの学習の場合、話者の多様性によって混合要素を十分に分離することは可能であるが、可能な分割が音声的なコンテキスト方向又は時間方向のものである場合は、新しい状態を加えることによって、この分散性をモデル化することはできない。その分割方法自体とは別に分割すべき状態を選択することにより、我々はまた非減少尤度の保証を失っている。但し、実際には、尤度の減少に出会うことはまれである。

【0010】本発明の第1の目的は以上の問題点を解決し、多数の話者の膨大な学習用テキストデータを必要とせず、従来例に比較して処理装置のメモリ容量の少なくすみ、その計算時間を短縮することができる不特定話者モデル作成装置を提供することにある。

【0011】また、本発明の第2の目的は、上記第1の目的に加えて、生成された不特定話者モデルを参照して音声認識することができ、従来例に比較して音声認識率を改善することができる音声認識装置を提供することにある。

【0012】

【課題を解決するための手段】本発明に係る請求項1記載の不特定話者モデル生成装置は、複数の特定話者の発聲音声データに基づいて話者独立型の隠れマルコフモデルを生成するモデル生成手段を備えた不特定話者モデル生成装置において、上記モデル生成手段は、複数の特定話者の発聲音声データに基づいて、バーム・ウェルチの学習アルゴリズムを用いて単一ガウス分布の隠れマルコフモデルを生成した後、上記単一ガウス分布の隠れマルコフモデルにおいて、1つの状態をコンテキスト方向又は時間方向に分割したときに、最大の尤度の増加量を有する状態を分割することを繰り返すことにより話者独立型の隠れマルコフモデルを生成することを特徴とする。

【0013】また、請求項2記載の不特定話者モデル生成装置は、請求項1記載の不特定話者モデル生成装置において、上記モデル生成手段は、複数の特定話者の発聲音声データに基づいて、バーム・ウェルチの学習アルゴリズムを用いて単一ガウス分布の隠れマルコフモデルを生成する初期モデル生成手段と、上記初期モデル生成手段によって生成された単一ガウス分布の隠れマルコフモデルにおいて、1つの状態をコンテキスト方向又は時間方向に分割したときに、最大の尤度の増加量を有する状態を検索する検索手段と、上記検索手段によって検索された最大の尤度の増加量を有する状態を、最大の尤度の増加量に対応するコンテキスト方向又は時間方向に分割した後、バーム・ウェルチの学習アルゴリズムを用いて単一ガウス分布の隠れマルコフモデルを生成する生成手段と、上記生成手段の処理と上記検索手段の処理を、単一ガウス分布の隠れマルコフモデル内の状態を分割することができなくなるまで又は単一ガウス分布の隠れマルコフモデル内の状態数が予め決められた分割数となるまで繰り返すことにより、話者独立型の隠れマルコフモデルを生成する制御手段とを備えたことを特徴とする。

【0014】さらに、請求項3記載の不特定話者モデル生成装置は、請求項2記載の不特定話者モデル生成装置において、上記検索手段によって検索される状態は、直前の処理で上記生成手段によって分割された新しい2つの状態に限定されることを特徴とする。

【0015】さらに、請求項4記載の不特定話者モデル生成装置は、請求項2記載の不特定話者モデル生成装置において、上記検索手段によって検索される状態は、直前の処理で上記生成手段によって分割された新しい2つの状態と、上記新しい2つの状態から距離が1だけ離れた状態とに限定されることを特徴とする。

【0016】またさらに、請求項5記載の音声認識装置は、入力される發聲音声文の音声信号に基づいて所定の隠れマルコフモデルを参照して音声認識する音声認識手段を備えた音声認識装置において、上記音声認識手段は、請求項1乃至4のうちの1つに記載の不特定話者モデル生成装置によって生成された話者独立型の隠れマルコフモデルを参照して音声認識することを特徴とする。

【0017】

【発明の実施の形態】以下、図面を参照して本発明に係る実施形態について説明する。

＜1．本実施形態の特徴＞図1は、本発明に係る一実施形態である不特定話者連続音声認識装置のブロック図である。本実施形態の音声認識装置は、特に、特定話者の発聲音声データメモリ30に格納された複数N人の特定話者の発聲音声データに基づいて、従来例のSSS法を改良した話者独立型SSS法（以下、SI-SSS法という。）を用いて、不特定話者の話者独立型HM網11を生成してそのメモリに格納する不特定話者モデル生成部31を備え、HM網11を参照して音声認識を行うことを特徴とする。この音声認識装置は、マイクロホン1と、特徴抽出部2と、バッファメモリ3と、音素照合部4と、文脈自由文法データベース20内の所定の文脈自由文法に基づいて生成されたLRテーブル13を参照して音声認識処理を実行する音素コンテキスト依存型LRバーザ（以下、LRバーザという。）5とを備える。

【0018】＜2．SI-SSS法の不特定話者モデル生成処理＞図2は、不特定話者モデル生成部31によって実行される不特定話者モデル生成処理を示すフローチャートである。ここで我々は、「話者独立型HM網のトポロジー学習問題」に対して従来例のSSS法とは異なる解決方法を提案する。すなわち、単に状態にとって最適な分割法を求める段階、及び分割に最適な状態の抽出段階とを再配列する方法である。SSS法と区別するため、ここではSI-SSS法と呼称するこの新アルゴリズムについて図2を参照して説明する。

【0019】図2において、ステップS11では、複数の特定話者の発聲音声データ（具体的には、発聲音声の特徴パラメータのデータである。）30に基づいてそれぞれ後述する所定の音声の特徴パラメータを抽出した後音素を切り出して、従来の方法で複数の特定話者用単一ガウス分布のHM網を生成する。そして、生成したHM網に基づいて、公知のバーム・ウェルチの学習アルゴリズムを用いて学習を行って単一ガウス分布のHM網を生成する。次いで、ステップS12では、HM網内のすべての状態に対して分割可能な状態の分割情報を得る。この処理は、ステップS15と同様に実行される。すなわち、詳細後述する最尤分割設定処理を用いてすべての状態に対して将来の分割の中で最良の分割方向及び音素（又は音素ラベル）を検索して決定し、これらを分割情報としてメモリに記憶する。すなわち、分割情報とは、以下の通りである。

（1）分割したときの期待される尤度の増加量、（2）分割は、コンテキスト方向であるか、時間方向であるか、並びに、（3）コンテキスト方向の前の音素、当該音素、後の音素。

【0020】次いで、ステップS13において、分割情報に基づいて最大の尤度の増加量を有する分割すべき状

態を検索し、検索した状態を分割情報に従って分割する、すなわち、最大の尤度を有する分割すべき状態を最良の方向（すなわち、コンテキスト方向か、時間方向）で分割する。さらに、ステップS14では、分割したときの被影響状態を検索して決定し、これらの被影響状態に対して公知のバーム・ウェルチの学習アルゴリズムを用いて学習を行って単一ガウス分布のHM網を生成する。そして、ステップS15で、詳細後述する最尤分割設定処理を用いて、ステップS13で分割された2つの状態及び被影響状態に対して将来の分割の中で最良の分割方向及び音素（又は音素ラベル）を検索して決定し、これらを分割情報としてメモリに記憶する。ここで、K個の被影響状態に対して（K-1）個のコンテキスト方向の分割テストと1個の時間方向の分割テストが実行される。ステップS16では、単一ガウス分布のHM網内の状態が分割不可能であるか、又は単一ガウス分布のHM網内の状態数が予め決められた分割数（以下、所定の分割数という。）となったか否かが判断され、分割可能でありかつ所定の分割数に達していないときはステップS13に戻って上記の処理を繰り返す。一方、ステップS16で分割が不可能であるとき、又は所定の分割数に達しているときは、ステップS17で得られたHM網11をメモリに格納する。

【0021】新しい状態のための初期状態の混合パラメータを計算するSSS法の処理の図12のステップS4は、音素コンテキストの最適な分割法を見つけるステップに非常に良く似ている。初期化には、異なるコンテキスト用のサンプル平均値に対して実施するVQ（ベクトル量子化）学習手順が含まれている。これは、詳細後述する分割アルゴリズムに類似している。この段階を少し改良し、後のテストのために最適な分割からの利得を保存することによって、図12のステップS3を効率良く省略し、同時に正確な走査を実現することができる。本実施形態のSI-SSS法のアルゴリズムのさらなる優位点は、バーム・ウェルチの学習アルゴリズムを用いて単一ガウス分布に対して学習を実行する点である。これは混合ガウス分布の場合より確かに早い速度で実行される。

【0022】バーム・ウェルチの学習アルゴリズムによる学習がSSS法アルゴリズムよりSI-SSS法アルゴリズムにおいて遙かに高速であるにも関わらず、この2つの方法による計算コストは、同一規模になると予想される。全ての被影響状態が更新された場合、両アルゴリズムにおけるコンテキスト方向の分割テストの回数は本質的に同数である。すなわち、被影響状態数をKと仮定した場合、SSS法は（K+1）回である一方、SI-SSS法はK回である。SI-SSS法のコンテキスト方向の分割テストは、従来例のSSS法の混合初期化段階より幾分高価であるが、これは最短距離よりクラスタリングの最尤規準の方を使用しているからである。但

し、その差は僅かなものであり、また、この段階はSSS法の全体的な計算量からすると比較的小さい部分でしかない。また、本実施形態のSI-SSS法の時間方向の分割も、詳細後述されるように、被分割状態から結果的に生じる2つのガウス分布に対してバーム・ウェルチの学習アルゴリズムを用いた学習を必要とすることから、SSS法の時間方向の分割において用いられる单一の前向きアルゴリズムバスに比較するとやはり経費が掛かるはずである。さらに、2回のSSS法による時間方向の分割テストに比べると、K回のSI-SSS法による時間方向の分割テストの方に可能性があるはずである。但し、時間方向の分割コストは、前向きアルゴリズムによるデータ処理量が小さく（单一状態に写像するのみ）、また、時間方向の分割は最大状態長の制約によって結果的に抑下されることから、すべてのアルゴリズムのコストのほんの一部を占めるだけである。従って、SI-SSS法の時間方向の分割の追加コストが問題となることはない。事実、詳細後述するように、本発明者による実験によれば、SI-SSS法は、分離された2620単語の話者依存型学習においてはSSS法より早いことが示されている。

【0023】たとえ、SI-SSS法の電子計算機の処理時間がSSS法と同等か、又は僅かに早いだけであるとしても、HM網の生成コストを削減する利点は依然として存在する。被影響状態の部分集合（サブセット）に関するパラメータの再初期化（SSS法用）、又は最適分割方法の再評価（SI-SSS法用）を行なうだけで、SSS法及びSI-SSS法両方のコスト削減が可能である。例えば、被影響状態に関しては以下の3つのレベルが指定可能である。

(A) 分割により生成される2つの新たな状態、(B)これら新たな2つの状態にすぐに近接する全ての状態、すなわち、分割された新たな2つの状態から距離1にある各状態、並びに、(C) その他のすべての被影響状態。言い換えれば、図2のステップS15において対象となる状態を、上記セット(A)のみにするか、上記セット(A)及び(B)のみにするか、上記すべてのセット(A)、(B)及び(C)としてもよい。

【0024】従来例のSSS法においては、セット(C)に属する状態の混合パラメータを再設定することは必要のない場合がある。SI-SSS法では分割による変更が最小限であることが予想されることから、セット(C)に当たる状態の分割パラメータを幾つか再推定することは理に適っている。電子計算機の使用を増やすためのSI-SSS法のオプションには以下のものが含まれる。

- (1) 同一の分割を保持し、分割の平均値と分散のみを更新して新しい利得を計算する。
- (2) 分割方向（例えば、左コンテキスト方向）を保持するが、早期の収束のために、前のコンテキストを用い

た分割アルゴリズムの初期化を行ってその方向におけるコンテキスト方向の最適分割を再評価する。

(3) 全般的な状態の再評価を行う。

【0025】注意を要する点は、2つの新しい状態については、可能な分割方法の全てに対して評価を行わなければならない。また全般的な再評価を行なわずに済むことのできるのは、その他の被影響状態だけであるという2点である。被影響状態が完全に再評価されれば、改善された本実施形態のS I - S S S法のアルゴリズムはどの段階においても、同一のHMMモデルから開始される従来例のS S S法のアルゴリズムに比べて学習データの尤度のより大きな増加を保証することになる。しかしながら、実際には完全な再評価を行なうことなく、かつかなりの低コストでも良い結果が達成される。

【0026】<3>、状態分割と条件付きML推定>分割生成に使用される可能性のある最大の尤度に関しては、3つの一般的な目標関数が存在する。最も単純なものは、他の幾つかの研究（従来文献9、10、及び12）で実証されているように、学習データを幾つかの事前指定されたトポロジーにおける状態に位置調整し、次いでその結果である状態分布をクラスタ化して、データ及び所定の状態シーケンスの接続尤度を最大化する方法である。この方法は、多くの用途において成功裡に使用されてきたもので本質的にはビタビスタイルの学習であるが、バーム・ウェルチの学習アルゴリズムに関連した部分最適として知られている。

【0027】第2のオプションは、観測データの尤度を直接的に最大化することであるが、尤度の算定には発話境界のような固定点間における前向きアルゴリズムの駆動が必要となる。従って、直接的な尤度規準が有効であるのは、S S S法における音素境界のような中間固定点が使用されている場合に限られる。分割尤度は、被分割状態が区分される固定された境界回数の範囲内で、全てのデータサンプル及び状態を前向きアルゴリズムを使用して算出する。分割結果の良好性の尺度には、それが真的尤度であり、隣接する状態に対する分割の影響を組み入れているという優位点がある。不利な点は、音素境界を必要とすることであり、特に、従来例のS S S法は、

$$\begin{aligned}
 Q(\theta | \theta^{(p)}) &= E[\log p(y_1^T, s_1^T | \theta) | y_1^T, \theta^{(p)}] \\
 &= \sum_{s_1^T} p(s_1^T | y_1^T, \theta^{(p)}) \log p(y_1^T, s_1^T | \theta) \\
 &= \sum_{s_1^T} p(s_1^T | y_1^T, \theta^{(p)}) \sum_t [\log p(y_t | s_t, \theta_{A(t)}) \\
 &\quad + \log p(s_t | s_{t-1}, \theta_{B(t)})] \\
 &= \sum_s r_t(s) \log p(y_t | s, \theta_{A(t)}) \\
 &\quad + \sum_{s, s'} \sum_{t, t'} \xi_t(s, s') \log p(s_t = s | s_{t-1} = s', \theta_{B(t)})
 \end{aligned}$$

【0034】ここで、

手動でラベル付けされた音素境界を付して使用されてきた。ビタビ法により調整された音素境界も、ほぼ同じように動作するものと思われるが、実験において検証されていない。但し、分割尤度規準の真の不利な点は単に、最も要求頻度の高いと思われるS I - S S S法において使用するには単に高価すぎることである。

【0028】この問題に対する我々の解答は、尤度より、標準的なバーム・ウェルチ学習アルゴリズムの背後にある期待値-最大値(Expectation Maximization: EM)のアルゴリズム（以下、EMアルゴリズムという。）の概念（従来文献13）。

P. Dempster et al., "Maximum Likelihood from Incomplete Data via the EM Algorithm", Journal of the Royal Statistical Society, Vol. 37, No. 1, pp. 1-38, 1977年を利用して、期待された対数尤度を最大化することである。EMアルゴリズムの背後にある基本的な結果は、観測データ y_1^T 及び隠された又は非観測要素 s_1^T の期待された対数尤度の増加を意味している。この要素は、例えば、HMMの状態である。期待された対数尤度 $Q(\theta | \theta^{(p)})$ は次式で表わすことができ、ここで、 $E\theta_{ip}$ はパラメータ θ_i (p) に関する対数尤度の期待値である。

【0029】

$$Q(\theta | \theta^{(p)}) = E\theta_{ip} + \log p(y_1^T, s_1^T | y_1^T, \theta)$$

【0030】ここで、最悪の場合でも、観測データ $L(\theta) = \log p(y_1^T | \theta)$ の尤度には変化を与えない。

【0031】

$$Q(\theta | \theta^{(p)}) \geq Q(\theta^{(p)} | \theta^{(p)}) = L(\theta) \geq L(\theta^{(p)})$$

【0032】HMMにおける条件付き独立の仮定により、期待された対数尤度は以下のように表すことができる。

【0033】

【数3】

$$r_t(s) = p(s_t = s | y_1^T, \theta^{(p)})$$

【数5】 $\xi_t(s, s')$ = $p(s_t=s, s_{t-1}=s' | y_1^T, \theta^{(t)})$

【0035】数3の形式は、各状態s毎の分布パラメータ $\theta_{A(s)}$ 及び遷移確率 $\theta_{B(s)}$ の分離最大化を考慮したものである。これによって、我々は期待された尤度が増加するように单一の状態（又は、分割後の2つの状態）に対するパラメータを推定することができ、それによって観測データの尤度に減少のないことが保証される。

【0036】特に、状態分割のHMM生成に際して、我々は $\gamma_t(s)$ 及び $\xi_t(s, s')$ が全ての $s \neq s^*$ に開じ固定されているという条件にしたがって $Q(\theta | \theta^{(t)})$ を最大化している。ここで、「 s^* 」は、状態s

$$\begin{aligned} G(s) &= \sum_{s=s_0, s_1} \sum_t \gamma_t(s) \log p(y_t | s, \theta_{A(s)}) \\ &\quad - \sum_t \gamma_t(s^*) \log p(y_t | s^*, \theta_{A(s^*)}) \\ &+ \sum_{s=s_0, s_1} \sum_{s'=s_0, s_1} \sum_t \xi_t(s, s') \log a_{s,s'} \\ &- \sum_t \xi_t(s^*, s^*) \log a_{s^*,s^*} \end{aligned}$$

【数7】

$$\begin{aligned} G(s) &= \sum_{s=s_0, s_1} N_1(s) \log p(y_t | s, \theta_{A(s)}) - N_1(s^*) \log p(y_t | s^*, \theta_{A(s^*)}) \\ &+ \sum_{s=s_0, s_1} \sum_{s'=s_0, s_1} N_2(s, s') \log a_{s,s'} - N_2(s^*, s^*) \log a_{s^*,s^*} \end{aligned}$$

【0038】ここで、 $a_{ss} = p(s_t=s | s_{t-1}=s', \theta_b(\theta))$ であり、次式の通りである

【0039】

【数8】

$$N_1(s) = \sum_t \gamma_t(s)$$

【数9】

$$\begin{aligned} G_O(s) &= \sum_{s=s_1, s_2} N_1(s) \log p(y_t | s, \theta_{A(s)}) - N_1(s^*) \log p(y_t | s^*, \theta_{A(s^*)}) \\ &= 0.5 [\sum_{m=1}^M [N_1(s^*) \log \sigma_m^2(s^*) - N_1(s_0) \log \sigma_m^2(s_0) \\ &\quad - N_1(s_1) \log \sigma_m^2(s_1)] \\ &\quad - N_1(s^*) \log [1 + \{N_1(s_0) N_1(s_1)\} / N_1(s^*)^2 \\ &\quad \cdot \sum_{m=1}^M (\mu_m(s_0) - \mu_m(s_1))^2 / \sigma_m^2(s^*)]] \end{aligned}$$

【0042】但し、分布は対角共分散によって記述され、下付き文字mはM次元ベクトル要素を表わすものと仮定する。この特別な利得の形式は、従来文献10に記載された、結合された平均値と共分散の尤度規準を使用

の被分割状態（分割された状態）を表しており、

「 s' 」は、状態sの1つ前の時間の状態を表わす。詳細後述するように、初期分割が適正に選択された場合、条件付き関数 $Q(\theta | \theta^{(t)})$ は、 $s \neq s^*$ に依存する項が変化せず、従って、他の項に関わる尤度も減少できないために、その非減少が保証される。従って、「 (θ) 」は、非減少として保証される。状態 s^* から状態 s_0 及び状態 s_1 への分割Sに対する期待された対数尤度の利得は以下のように求められる。

【0037】

【数6】

$$N_2(s, s') = \sum_t \xi_t(s, s')$$

【0040】観測分布パラメータのみによる利得は、以下のように表すことができる。

【0041】

【数10】

している（従来文献14 T. W. Anderson, "An Introduction to Multivariate Statistical Analysis", J. Wiley & Sons, New Y

ork, 1984年)の第10節3項の結果に基づく。)、コンテキスト方向の分割の場合、状態遷移確率は一定に保持され、数10は期待された全体の利得をもたらす。一方、時間方向の分割では、期待された全体の

$$\begin{aligned} G_{\text{Temporal}}(S) &= G_0(S) - N_2(s^*, s^*) \log a_{s^*s^*} + N_2(s_0, s_0) \log a_{s_0s_0} \\ &\quad + N_2(s_0, s_1) \log a_{s_0s_1} + N_2(s_1, s_1) \log a_{s_1s_1} \\ &= G_0(S) - N_2(s^*, s^*) \log a_{s^*s^*} + N_2(s_0, s_0) \log a_{s_0s_0} \\ &\quad + (N_1(s_0) - N_2(s_0, s_0)) \log(1 - a_{s_0s_0}) + N_2(s_1, s_1) \log a_{s_1s_1} \end{aligned}$$

【0044】数10及び数11によって得られる規準を使用すれば、分割方向の範囲内、及び範囲外の、また状態間での異なる分割候補を比較し、すべての学習セットの期待される尤度を最大化させる分割を選択することができる。ただ数10及び数11は、尤度自体の増加ではなく、期待される尤度の増加を示しているため、SにわたるG(S)の最大化は、尤度が非減少であることのみを保証するものであり、必ずしも尤度を最大化させる分割を選択しているという点を保証するものではないということに注意すべきである。

【0045】数10及び数11の尺度は、観測と状態の期待される結合尤度が増大するため、従来例のSSS法において観測尤度に基づく分割方向の選択に使用されたテストとは異なる形式となっている。さらに、これらの数10及び数11は、分割に最も適したノードを決定する際にもSSS法で使用される規準(従来文献1の式(1))とは異なる形式を採用しているが、この場合は、SI-SSS法の規準の方が望ましい。従来例のSSS法の規準は、2つの包括的混合要素の間の距離の度合いであり、単一状態を有することに関連する尤度の利得ではない。まして、学習データの尤度の増加に関連づけられるようなものではない。

【0046】分割によるHMM生成における状態尤度 $\gamma_t(s)$ 及び $\gamma_t(s, s')$ の使用は、メモリ容量の増大化を意味している。メモリ容量を減少させるために、我々は従来例のSSS法で使用された技術を利用している。それは、音素境界(手動でラベル付けされた又はビタビ法により調整された)を使用して各回毎に非ゼロ確率を有する状態のセットを制約する(すなわち $\gamma_t(s)$ のサイズの減少させる)というものである。

【0046】<4. コンテキスト方向分割の効率的なサーチ>従来例のSSS法は基本的には分割クラスタリングのアルゴリズムであるため、類似問題の処理における進歩(すなわち、決定木による設計(従来文献15

L. Breiman et al., "Classification and Regression Trees", Wadsworth International Group, 1984年(参照)から恩恵を享受することができる。決定木による設計における問題は、XからYを予測するための関数 $Y = h(X)$ を設計することである。Yが値 $v \in R^n$ をとる場合、当該閏

利得は以下の式で求められる。

【0043】

【数11】

数は通常、回帰木と呼ばれる。また、 $y \in \{1, \dots, M\}$ である場合には分類木と呼ばれる。決定木関数 f は、Yを直接的に予測するよりむしろ、音声認識(従来文献16)L. Bahl et al., "A tree-based statistical language model for natural language speech recognition", IEEE Transactions on Acoustic Speech, and Signal Processing, Vol. 37, No. 7, pp. 1001-1008, 1989年(参照)で使用される本言語モデルの場合のように確率分布 $P_h(y|X) = P(y|f(X))$ を推定するために使用可能である。推定分布の解釈は、音声認識(例えば、従来文献10、11参照)における分割分布クラスタリングの使用に対応しているため、決定木による設計方法をここで適用している。

【0047】決定木による設計又は一般にいう分割クラスタリングにおける典型的なアプローチは、旺盛に成長するアルゴリズムであり、各段階で目的関数を最も進歩させる分割を行ないながら連続的に木を成長させていく。このアルゴリズムは、可能性のある全ての木の葉、すべての可能な変数 X (Xの要素)、及び変数 X 上で分割可能なすべての方法についてテストを行うことを要求している。変数 X 用の最適分割の選択が最も頻度の高いルーチンであることから、それが比較的高速であることが重要である。離散変数 X が値 J を持っている場合、テストすべきバイナリー分割(又は2分割)は約 2^{J-1} 個存在し、これはほとんど絶望的に高価である。従来文献15のブレーマンほかは、 $M=2$ である場合に関しては、素早い解答を与えており、後に、従来文献17 P. A. Chou, "Optimal partitioning for classification and regression trees", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 13, No. 4, pp. 340-354, 1991年4月において、ジョウは、さらに一般的な事例($J \geq 2$ 及び $M \geq 2$)に対する高速分割設計用のアルゴリズムを提供している。ジョウのアルゴリズムは、単に多くの木設計の目標関数に対して局部

的な最適化を示すだけであるにも関わらず、M及びJに比例していることから、M>2の場合には、こうしたパラメータの1つ又はその他方において指数関数的である。先に提案されたCARTアルゴリズム（従来文献15）よりもさらに効率が良い。例えば音素モデルを使用するHM網の生成問題においては、Xは分割可能方向（例えば時間的、又は左、右又は中央音素コンテキスト方向）である絶対的な（無条件の）変数で構成されている。コンテキスト方向の何れに対しても、Xの値は音素ラベルであり、日本語ではN=26音素である。従って、状態分割に関するHM網の生成問題は、決定木の無条件の質問設計に類似しており、可能性のある分割を効率的にサーチするためのアルゴリズムの恩恵を受けることができる。

【0048】我々は、以下でジョウの2分割アルゴリズム（従来文献17参照。）について再検討することから開始し、次いでこのアルゴリズムが最大のガウスログ尤度の目的関数にどのように適用されるかを示す。我々は「HMM生成への適用」を明確にするため、「ノード」ではなく「状態」、「木」ではなく「HM網」といった用語を使用して、標準的な決定木の専門用語（及び簡略表記法）を用いて説明する。標準的な決定木の設計との1つの相違点は、観測データを单一のノード又は状態に割り当ることではなく、異なった状態にある観測データの尤度を記述する確率分布が存在していることである。最初の議論を単純化するために、観測データはビタビ法による調整（学習）によって得ることができる唯一の状態に関連するものと仮定する。次いで、その結果をバーム・ウェルチの学習アルゴリズムに使用できるように拡張する方法を示す。

【0049】<4. 1 一般的な絶対的な分割生成アルゴリズム>以下では、変数Xを使用して状態sを分割するためのジョウ（従来文献17参照。）による分割アルゴリズムについて説明する。仮に状態sに導く変数xがセットA_sを形成すると仮定しよう。我々はまず、観測データI_s(y, v_h)を、HM網の（又は決定木）生成において最小化されるべき損失関数と定義することから開始する。変数y_hはyの1つの表示であって、量子化、回帰又は直接分類の場合と同様に、Yと同じ空間における値を取ることが可能であり、もしくは、上記の本言語モデル及び分布クラスタリング例の場合と同様に、Yを表す確率分布とすることができます。HM網における

$$\begin{aligned} i(s) - i_{ij}(s) \\ = |i(s) - i_z(s)| + |i_z(s) - i_j(s)| \\ = \Delta_1 + \Delta_2 \end{aligned}$$

【0061】i(s)及びi_{ij}(s)は定数であるため、それらの差異も固定値であり、旺盛に成長する分割設計においては公知であるように、Δ₁を最大にすることは、Δ₂を最小にすることと等価である。ジョウは、次式を示している。

状態sの不純性は、ある状態における期待される最小損失であり、以下の式で与えられる。

【0050】

$$【数12】 i(s) = E[L(Y, \theta(s)) | s]$$

【0051】ここで、E[f(Y) | s]は、S=sと仮定したときの条件付き期待値であり、θ(s)は状態sのセントロイド（重心、質量重心）であり次式で表される。

【0052】

【数13】

$$\theta(s) = \underset{y h}{\operatorname{argmin}} E[L(Y, y h) | s]$$

【0053】発散d(s, y h)は、状態sを表すものとしてセントロイドθ(s)の代わりにy hを使用するときと比較したときの、期待された損失における差である。

【0054】

【数14】

$$d(s, y h) = E[L(Y, y h) | s] - i(s)$$

【0055】状態sに対して分割を行うときにおいては、我々はまずi(s)を固定値とし、次式で表わされるi_{ij}(s)を、J個のアレイに分割することによって達成される可能な最小不純度（これも固定値である）として開始する。

【0056】

【数15】

$$i_{ij}(s) = \sum_j p(x_j | s) i(x_j)$$

【0057】ここで、x_jは、コンテキスト方向のファクタ_xが取り得る可能な値である。状態s₀及びs₁へのバイナリ分割の不純度は以下の式で表される。

【0058】

【数16】

$$i_z(s) = \sum_{k=0,1} p(s_k | s) i(s_k)$$

【0059】いま、次式のようにおく。

【0060】

【数17】

【0062】

【数18】

$$\Delta_2 = \sum_j p(x_j | s) d(x_j, \theta(\alpha(x_j)))$$

【0063】この式は、「Δ₂の最小化は量子化器の設

計問題として解釈することが可能である」ということを意味しており、その目標は、予想される発散を最小化するための「エンコーダ」 $\alpha(x_j)$ 及び「デコーダ」又はセントロイド $\theta(s_k)$ を設計することにある。ここで、エンコーダは、 $K=0, 1$ に対してパーティション $A_K = \{x_j : \alpha(x_j) = s_k\}$ として記述が可能である。この問題に対する局部的に最適な解は、 K -平均値アルゴリズム、又はベクトル量子化（従来文献18）

[Y. Linde et al., "An algorithm for vector quantizer design", IEEE Transactions on Communication, vol. CO

$$\alpha(x_i)^{(t+1)} = \operatorname{argmin}_i$$

【0066】ここで、「 argmin_i 」は引数を最小にする i の値を示す関数であり、数19は $k=0, 1$ のときに次式を与える。また同様に、「 argmax_i 」に代えて、「 argmax_i 」のときは、引数を最大にする i の値を示す関数である。

【0067】

【数20】 $A_k^{(t+1)} = \{x_j : \alpha(x_j)^{(t+1)} = k\}$

【0068】(2) $k=0, 1$ に対して新しいデコーダ $\theta(s_k)^{(t+1)}$ を見つける。

【0069】

【数21】

$$\theta(s_k)^{(t+1)}$$

$= \operatorname{argmin}_{\theta} E[L(Y, \theta) | s_k]$

θ

$= \operatorname{argmin}_{\theta} \sum_{x_i \in A_k^{(t+1)}} p(x_i | s_k) d(x_i, \theta)$

【0070】無条件の予測の特別な場合に対して、ジョウの反復の分割アルゴリズムは、ナーダスほか（従来文献19）[A. Nadas et al., "An iterative "flip-flop" approximation of the most informative split in the construction of decision trees", Proceedings of the International Conference on Acoustic Speech and Signal Processing, pp. 565-568, 1991]によって提案された反復アルゴリズムと同様であるが、最小値 Δ_2 に対する最大値 Δ_1 の解釈によってこの2段階のメカニズムには差異がある。

【0071】ジョウ（従来文献17）は、例えば、回帰のための重み付け2乗エラー値 ($y \in R^m$) 及び分類のための重み付けギニ・インデックス (Gini index) 及び対数尤度 ($y^T = 100 \dots 010 \dots 0 + \text{クラスM}$ を指示するために第m列に1を有するM値のクラスインディケータ) 等を含む種々の損失関数によ

M-28, pp. 84-95, 1980年1月) のためのリンデ・ブゾー・グレイ (Linde-Buzo-Gray) のアルゴリズムと類似する反復アルゴリズムを使用して求めることができる。すなわち、これは収束し、又は、平均的な損失の相対的な変化量が幾つかのしきい値より小さくなるまで、パラメータ α 及び θ の再推定を反復することである。さらに明確に言えば、以下の2つのステップを実行することである。

【0064】(1) 各 x_i に対して、新しいエンコーダ $\alpha(x_i)^{(t+1)}$ を見つける。

【0065】

【数19】

$$d(x_i, \theta(s_i)^{(t)})$$

ってこのアルゴリズムが使用可能であることを示している。ここでは、ガウス分布によって分布が特徴づけられていると仮定して、特に最大の対数尤度の目的関数のためのアルゴリズムについて特に説明する。

【0072】<4.2 最大ガウス対数尤度の使用>ガウス分布のクラスタリングの問題に関して、 $y \in R^m$ は我々の音声認識のアプリケーションにおけるケプストラムベクトルに対応している。 X の各要素は可能な分割方向（例えば、左コンテキスト方向の音素ラベル）であり、 N は J 値の離散セットをとる X の要素である（例えば、26個の可能な日本語の音素である）。我々は、平均値 $\mu(s)$ 及び共分散行列 $\Sigma(s)$ によってパラメトリック・ガウス分布のHMMモデル $P(y | s)$ を仮定する。従って、状態は $\theta(s) = (\mu(s), \Sigma(s))$ によって表される。状態 s に対応する X の可能な値の空間は、 A_s によって特徴づけられていることを思い出させる。目標は、 $A_s = A_0 \cup A_1$ である場合に、状態 s_0 及び s_1 への状態 s の最適な分割を見つけることにある。

【0073】再度、一般的なアルゴリズムについて言及すると、予め決められた幾つかの観測データ $L(y, \theta)$ に基づいて、 $d(s, \theta)$ 及び最適デコーダを見つけるための式を決定する必要がある。目的が最大尤度（最尤）である場合は、観測データは、 $L(y, \theta) = -\log P(y | \theta)$ と表わすことができる。この目的関数のもとでは、数13は以下のようになる。

【0074】

【数22】

$$\theta(s)$$

$= \operatorname{argmin}_{\theta} E[L(Y, \theta) | s]$

θ

$= \operatorname{argmax}_{\theta} E[\log p(Y | \theta) | s]$

θ

$= \operatorname{argmax}_{\theta} \sum_{t : x_t \in A_s} \log p(y_t | \theta)$

θ

$t : x_t \in A_s$

【0075】ここで、数22の第3式において、 $t : x$

$t \in A_s$ の Σ は、 x_t が A_s に属するときの t を変化して $(\log p(y_t | \theta))$ の和を計算するものである。我々は学習用データから学習しており、また真値 $P(y | s)$ が未知であるために、ここでは経験的分布を使用している。このことは、標準的な最大尤度のパラメ

$$\begin{aligned} d(s, \theta) &= E[L(Y, \theta) | s] - i(s) \\ &= -\sum_{t : x_t \in A_s} \log p(y_t | \theta) + \sum_{t : x_t \in A_s} \log p(y_t | \theta(s)) \\ &= (1/2) [N_s \log |\Sigma| + \sum_{t : x_t \in A_s} (y_t - \mu)^T \Sigma^{-1} (y_t - \mu) \\ &\quad - N_s \log |\Sigma(s)| - \sum_{t : x_t \in A_s} (y_t - \mu(s))^T \Sigma(s)^{-1} (y_t - \mu(s))] \end{aligned}$$

【0077】ここで、 N_s は、状態 s を写像（又はマッピング）するときの観測回数であり、 $\theta = (\mu, \Sigma)$ である。上付きの記号 $|t|$ はベクトル転置行列を指し、 $|A|$ は行列 A の行列式を表す。単一の J 個の変数のための状態 s におけるバイナリー分割設定処理は次のように実行される。

【0078】図3に、図2のステップS15で用いる最大分割設定処理を示す。図3において、まず、ステップS21で、2つの仮定状態の单一生ガウス分布の分布パラメータに対して次式のように初期値を割り当てる。

【0079】

【数24】

$$\theta^{(0)}(s_0) = \theta(s) = (\mu(s), \Sigma(s))$$

$$\sum_{t : x_t = x_1} \log p(y_t | \theta^{(0-1)}(s_0)) \geq \sum_{t : x_t = x_1} \log p(y_t | \theta^{(0-1)}(s_1))$$

【0082】ステップS25でYESであれば、ステップS26で各音素ラベル x_j , $j = 1, \dots, J$ に対して、パーティション $A_0^{(0)}$ に x_j を割り当て、NOであれば、ステップS27でパーティション $A_1^{(0)}$ に x_j を割り当てる。そして、ステップS28でパラメータ j が個数 J であるか否かが判断され、Kでないときは、ステップS29でパラメータ j を1だけインクリメントしてステップS25に戻り上記の処理を繰り返す。ステップS28でYESであるとき、ステップS30で、標準

$$\begin{aligned} \Sigma^{(p)}(s_k) &= (1/N_k) \sum_{x_i \in A_k^{(p)}} (y_i - \mu^{(p)}(s_k))(y_i - \mu^{(p)}(s_k))^T \\ \text{ここで、 } N_k &= \sum_{x_i \in A_k^{(p)}} \end{aligned}$$

である。

【0084】また、 N_j は $|t : x_t = x_j|$ における要素の数であり、 $N_j + N_1 = N_s$ である。次いで、ステップS31で第1の収束条件としてパーティションは変化しないか否かが判断され、変化するときはメインループに戻るが、変化しないときはステップS32で第2の収束条件として、次の数29を満足するか否かが判断される。

ータ推定であり、これは、平均値 $\mu(s)$ 及び共分散 $\Sigma(s)$ を与えていることに留意する。従って、数21で表される発散は以下になる。

【0076】

【数23】

【数25】

$$\theta^{(0)}(s_1) = (\mu(s) (1+\varepsilon), \Sigma(s))$$

【0080】この特別な選択によって、状態の1つが元の状態の分布パラメータを持っているため、ベクトル量子化器設計で使用される方法と同様に、尤度が増加することが保証される。次いで、ステップS22でパラメータ j に1がセットされ、ステップS23で新しいパーティション $|A_0^{(p)}, A_1^{(p)}|$ （具体的には、分割された状態である。）を見つける、そして、ステップS23でパラメータ j に1をセットし、ステップS25で次の数26が成立するか否かが判断される。

【0081】

【数26】

的な最大尤度パラメータ推定法によりセントロイド $\theta^{(0)}(s_E) = (\mu^{(0)}(s_E), \Sigma^{(0)}(s_E))$: $K = 0, 1$ を次式を用いて計算する。

【0083】

【数27】

$$\mu^{(p)}(s_k) = (1/N_k) \sum_{t : x_t \in A_k^{(p)}} y_t$$

【数28】

【0085】

【数29】 $(L^{(p)} - L^{(p-1)}) / L^{(p-1)} < \varepsilon$ ここで、

【数30】 $L^{(p)} = -N_s \log |\Sigma^{(p)}(s_0)| - N_1 \log |\Sigma^{(p)}(s_1)|$

【0086】ここで、 ε は発見的に選択された収束のためのしきい値である。また、次式が満足することに注意する。

【0087】

【数31】 $L^{(p)} \geq L^{(p-1)}$

【0088】ステップS32で、数29を満足するならば、メインループに戻り、一方、数29を満足しないならば、ステップS33でパラメータ ρ を1だけインクリメントしてステップS23に戻り上記の処理を繰り返す。

【0089】上記アルゴリズムの両段階に対しては、あらゆるデータポイントに関するログ確率を累積することよりも十分な統計量を使ってデータを示すことにより計算過程を保存することができる。特に、まず、対象となる変数Xが取る得る各 x_i において対して、状態sに関連したデータ y_t について記述する累積統計量を計算する。ここで、 N_j は $X=x_j$ を有する状態sにおけるサンプル（フレーム）数を表すものとする。そして、次式のように、1次及び2次統計量を定義する。

【0090】

$$\begin{aligned} & 2N_1 \log |\Sigma(s_0)| + \sum_{t: x_t = x_1} (y_t - \mu(s_0))^T \Sigma(s_0)^{-1} (y_t - \mu(s_0)) \\ & \leq 2N_1 \log |\Sigma(s_1)| + \sum_{t: x_t = x_1} (y_t - \mu(s_1))^T \Sigma(s_1)^{-1} (y_t - \mu(s_1)) \end{aligned}$$

【0093】記号法を簡略化するため、反復回数を示す上付きの記号(p)を省略する。総和の項は、数32及び数33により与えられる統計量を使用するため、以下

$$\begin{aligned} & \sum_{t: x_t = x_1} (y_t - \mu(s_0))^T \Sigma(s_0)^{-1} (y_t - \mu(s_0)) \\ & = \sum_{t: x_t = x_1} t^T r [(y_t - \mu(s_0))^T (y_t - \mu(s_0)) \Sigma(s_0)^{-1}] \\ & = t^T r [\sum_{t: x_t = x_1} (y_t - \mu(s_0))^T (y_t - \mu(s_0)) \Sigma(s_0)^{-1}] \\ & = t^T r [\Sigma(y_t y_t^T - y_t \mu(s_0)^T - \mu(s_0) y_t^T + \mu(s_0) \mu(s_0)^T) \Sigma(s_0)^{-1}] \\ & = t^T r [(S_1^2 - S_1^{-1} \mu(s_0)^T - \mu(s_0) (S_1^{-1})^T + N_1 \mu(s_0) \mu(s_0)^T) \Sigma(s_0)^{-1}] \end{aligned}$$

【0095】ここで、恒等式 $z^T A z = t^T (zz^T)^{-1} A (zz^T) z = t^T r (zz^T)^{-1} A (zz^T) z = t^T r (A) z$ 、及び追跡関数 $t^T r(\cdot)$ が1次演算子であるという事実を使用した。これらの結果を数34に組み合えると、以下のようないすれの式が得られる。

【0096】

$$\begin{aligned} & 2N_1 \log |\Sigma(s_0)| + \text{tr}[(S_1^2 - 2S_1^{-1}\mu(s_0)^T + N_1\mu(s_0)\mu(s_0)^T) \Sigma(s_0)^{-1}] \leq 2N_1 \log |\Sigma(s_1)| \\ & + \text{tr}[(S_1^2 - 2S_1^{-1}\mu(s_1)^T + N_1\mu(s_1)\mu(s_1)^T) \Sigma(s_1)^{-1}] \end{aligned}$$

【0097】十分な統計量を使用するパラメータ再推定

$$\begin{aligned} & \Sigma(s_k) \\ & = (1/N_k) \sum_{x_i \in A_k} \sum_{t: x_t = x_i} (y_t - \mu(s_k))^T (y_t - \mu(s_k)) \\ & = (1/N_k) \sum_{x_i \in A_k} \sum_{t: x_t = x_i} (y_t y_t^T - y_t \mu(s_k)^T - \mu(s_k) y_t^T + \mu(s_k) \mu(s_k)^T) \\ & = (1/N_k) \sum_{x_i \in A_k} (S_k^2 - S_k^{-1} \mu(s_k)^T - \mu(s_k) (S_k^{-1})^T + N_k \mu(s_k) \mu(s_k)^T) \end{aligned}$$

【0099】尤度テスト、及びパラメータ再推定方程式

【数32】

$$S_1^{-1}(s) = \sum_{t: x_t = x_1, s_t = s} y_t$$

【数33】

$$S_1^{-2}(s) = \sum_{t: x_t = x_1, s_t = s} y_t y_t^T$$

【0091】状態sに関するこうした統計量は、初期化段階で一度計算され、回数 N_j と共にメモリに格納されている。下記のパラグラフでは、再分割テスト（数27）及びパラメータ再推定におけるこうした統計量の使用方法を示している。ここで、まず、再分割テスト（数26）を拡張することについて説明する。

【0092】

【数34】

のように簡略化することができる。

【0094】

【数35】

方程式は以下の通りである。

【0098】

【数37】

$$\begin{aligned} & \mu(s_k) \\ & = (1/N_k) \sum_{x_i \in A_k} \sum_{t: x_t = x_i} y_t \\ & = (1/N_k) \sum_{x_i \in A_k} S_k^{-1}(s) \end{aligned}$$

【数38】

の両方は、もし対角共分散であると仮定すれば簡略化さ

れる。クラスタ尤度テストを簡単化するために、以下の式が成立することに留意する必要がある。

【O100】

【数39】

$$\log |\Sigma| = \sum_{m=1}^M \log \sigma_m^2$$

【数40】

$$C_0 + \sum_m \{ S_{1,m}^2(s) - 2 S_{1,m}^{-1}(s) \mu_m(s_0) + N_m \mu_m(s_0)^2 \} / \sigma_m^2(s_0)$$

$$\leq C_1 + \sum_m \{ S_{1,m}^2(s) - 2 S_{1,m}^{-1}(s) \mu_m(s_1) + N_m \mu_m(s_1)^2 \} / \sigma_m^2(s_1)$$

ここで、

【数42】

$$C_k = N_k \log \left(\prod_m \sigma_m^2(s_k) \right)$$

【O103】また、共分散行列が対角行列であると仮定

$$\sigma_m^2(s_k) = (1/N_k) \sum_{x_i \in A_k} (S_{1,m}^2 - 2 S_{1,m}^{-1} \mu_m(s_k) + N_m \mu_m(s_k)^2)$$

【数44】

$$\sigma_m^2(s_k) = \mu_m(s_k)^2 + (1/N_k) \sum_{x_i \in A_k} (S_{1,m}^2 - 2 S_{1,m}^{-1} \mu_m(s_k))$$

ここで、 $m = 1, \dots, M$ である。

【O105】このアルゴリズムを、ビタビ・アルゴリズムではなくバーム・ウェルチの学習アルゴリズムを介して、観測データが状態に蓋然的に（見込みに基づいて）関連している場合にまで拡張するために、更新されている状態に存在する尤度によって、単に数32及び数33の和の内側の各項を単に重み付けする。特に、 $r_t(s)$ を時間 t のときの状態を s であるときの確率に対応させる。このとき、新しい十分な統計量は次式で表される。

【O106】

【数45】

$$S_{1,t}^{-1}(s) = \sum_{t : x_t = s} r_t(s) y_t$$

【数46】

$$S_{1,t}^{-2}(s) = \sum_{t : x_t = s} r_t(s) y_t y_t'$$

【数47】

$$N_t(s) = \sum_{t : x_t = s} r_t(s)$$

【O107】 $r_t(s)$ 項は、前向き及び後向きパスの両方を使用して計算するものとする。原理上、この情報は、SSS法及びSIS-SSS法におけるバーム・ウェルチの反復から利用可能であるが、SSS法にはこの情報を全て格納するためのデータ構造がなく、SIS-SSS

$$t \cdot r(\Sigma_A \Sigma_B^{-1}) = \sum_{m=1}^M \sigma_{A,m}^{-2} / \sigma_{B,m}^{-2}$$

【O101】依って、新しい再分割テストは以下のようになる。

【O102】

【数41】

した場合、数38は次式のように簡単化される。

【O104】

【数43】

S法の場合はそれを付加する必要がある。SSS法では、分割に最適なノード、及びノードが決定されている場合の最適な分割方法の何れかを求めるに当たって $r_t(s)$ の項を必要としない。これは、分割に最適なノードは包括的な混合ガウス分布から選択され、最良の分割は前向きアルゴリズムを使用するためである。

【O108】<5. 時間分割の制約つきHM網の生成> HM網の生成における我々の目標は、前述されたサーチ方法を用いて、各ステップ毎に学習用データの尤度を最大にまで増加させることである。我々は、上述のように、制約つきEM（期待値-最大値）アルゴリズムの方法を肯定する議論を行ったが、これは、HM網に予想される尤度の増加量が、全体でも被分割状態と2つの新しい状態の期待される尤度の差に過ぎないというものである。並行する2つの状態の尤度は和をとれば元の状態の尤度になることから、コンテキスト方向の分割において前後の方向数を制限することは、すなおな方法である。しかしながら、シーケンス内の2つの状態の尤度は、単純な和によって与えられない。

【O109】本実施形態のSSS法において、時間方向分割は、HMMの前向きアルゴリズムの使用、及び分割された状態以外の状態の状態尤度（ $r_t(s)$ ：時間 t における状態 s の尤度）の変更を含む。この場合、ネットワークの大部分は、HM網の全体としての尤度における変化を確立するように評価する必要がある。できる限

り大きなサブネットワークを評価するために必要な追加コストに加えて、他の状態の尤度が、時間方向の分割に対して変化するが、コンテキスト方向で変化しないという問題は、時間の方向で分割することを選択する方向に向かうバイアスとなるであろう。

【O110】制約つきEM基準は、時間方向の分割の設計におけるこうした問題点を処理するものであり、被分割状態以外の状態の尤度は分割設計のパラメータ推定段階において変化しないという制約がある。より明確化するために、図5のように状態 s^* を分割された状態とし、状態 q_0 及び q_1 を時間方向の分割によって得られる2つの状態とする。これらの関係をより明確にするため、仮説の新しい状態を q とし、分割された状態候補を s^* と表記する。新しい状態を記述するために推定しなければならないパラメータ θ は、 $\theta = (\mu(q_0), \sigma(q_0), \nu(q_0), \mu(q_1), \sigma(q_1), \nu(q_1))$ である。ここで、 $\mu(q)$ は状態 q の平均値ベクトルであり、 $\sigma(q)$ は分散量ベクトルであり、 $\nu(q)$ は状態 q から状態 q' への復帰確率。すなわち、セルフループ状の遷移確率を意味する。HM網におけるこうしたパラメータのみが変動し、他は変動しないという点を保証するためには、次のような制約が必要である。

【O111】

$$\begin{aligned} \text{【数48】 } r_t(s^*) &= r_t(q_0) + r_t(q_1) \\ &\quad + \xi_t(q, q') \\ &= p(q_t=q, q_{t-1}=q' | Y) \\ &= p(q_t=q, q_{t-1}=q', s_t=s^*, s_{t-1}=s^* | Y) \\ &= \xi h_t(q, q') \xi_t(s^*, s^*) \end{aligned}$$

【O114】項 $r_t b(q)$ 及び $\xi_t b(q, q')$ は、 $r_t(s^*) > 0$ であるデータのみを使用し、かつ $r_t b(q_0) + r_t b(q_1) = 1$ となるような状態 q_0 及び q_1 に対してのみの非ゼロ状態尤度を有する前向き—後ろ向き標準アルゴリズムを用いて計算することができる。従って、前向き—後ろ向きアルゴリズムを制約することは、単に前向きパス及び後ろ向きパスを適正に初期化し、もしくは、図6のハッチング部分として表されているようなすべてのデータ構造のサブセットを通過さ

$$\begin{aligned} \mu_\circ(q) \\ = \left\{ \sum_t r h_t(q) r_t(s^*) y_{t+1} \right\} / \left\{ \sum_t r h_t(q) r_t(s^*) \right\} \end{aligned}$$

【数57】

$$\begin{aligned} \sigma_\circ(q) \\ = \left\{ \sum_t r h_t(q) r_t(s^*) y_{t+1}^2 \right\} / \left\{ \sum_t r h_t(q) r_t(s^*) - \mu_\circ(q)^2 \right\} \end{aligned}$$

【数58】

$$\begin{aligned} \nu(q) \\ = \left\{ \sum_t \xi h_t(q, q) \xi_t(s^*, s^*) \right\} / \left\{ \sum_{q'} \sum_t \xi h_t(q', q) \xi_t(s^*, s^*) \right\} \end{aligned}$$

【O116】ここで注意すべきことは、項 $r_t b(q)$ 及び $\xi_t b(q, q')$ の計算に使用される前向き—後

$$\begin{aligned} \text{【数49】 } \xi_t(s^*, s^*) &= \xi_t(q_0, q_0) + \xi_t \\ &(q_1, q_0) + \xi_t(q_1, q_1) \end{aligned}$$

ここで、

$$\text{【数50】 } r_t(i) = p(s_t=i | Y)$$

【数51】

$$\xi_t(i, j) = p(s_t=i, s_{t-1}=j | Y)$$

【O112】ここで、上記の式はHMMの再推定に必要な一般的な項であり、Yはすべての学習セットを表している。これらの制約条件は、数52及び数53を定義しかつ条件つき確率及び冗長性 $s_t = s^*$ の定義を用いることにより、容易に満足させることができ、数54及び数55を得ることができる

【O113】

【数52】

$$r h_t(q) = p(q_t=q | s_t=s^*, Y)$$

$$\text{【数53】 } \xi h_t(q, q') = p(q_t=q, q_{t-1}=q' | s_t=s^*, s_{t-1}=s^*, Y)$$

【数54】

$$r_t(q)$$

$$= p(q_t=q | Y)$$

$$= p(q_t=q, s_t=s^* | Y)$$

$$= \xi h_t(q) \xi_t(s^*)$$

【数55】

せるということに過ぎない。図6は、 $r h_t(q)$ 及び $\xi h_t(q, q')$ を時間方向の分割に対して計算するときに用いるデータと状態とを示し、ここで、図6において、0は、不可能な状態を示している。一旦、項 $r_t b(q)$ 及び $\xi_t b(q, q')$ が計算されると、次式に従ってパラメータ θ を計算する。

【O115】

【数56】

に用いることができない。従って、尤度における相対的な変化は、時間方向の分割の再学習のための停止基準として用いることができない。分割は後にバーム・ウェルチの学習アルゴリズムによって再学習されるため、単に固定された数の再学習の反復を実行することが妥当であり、ここでは4回の反復を使用した。

【0117】時間方向の分割によるHMM生成における問題は、コンテキスト方向の分割とは異なり、非減少尤度の保証がない点である。S I-S S S法による時間方向の分割再推定方法の場合は、それがEMアルゴリズムの制約つきバージョンであるために非減少尤度が保証されているが、1つの状態から2つの状態への分割においては、尤度が減少しないことを保証するように初期設定することができない。この処理において採用している適切な初期推定は、元の状態の観測分布を使用し、かつ、仮説の2つの状態における期待される持続時間の和が元の状態の期待される持続時間と同一になるように、遷移確率を選択するものである。実際には、まれではあるが時に尤度の減少は生じる。この場合、その状態の時間方向への分割は絶対に選択されない。S S S法の時間方向分割アルゴリズムも同様の問題を抱えている。これは、ガウス分布の固定されたセット用に最適の時間方向の分割を選択するからであるが、このガウス分布は時間方向の分割を特に想定して設計されたものではないため、こういった分割には必ずしも整合しない。しかしながら、ノードは混合要素間の距離に基づいて、実際の結果に合わせず分割されるため、従来例のS S S法のアルゴリズムは、悪い時間方向の分割を回避することができない。もちろん、S S S法のアルゴリズムは、分割処理において状態の再調整を実行することによって、S I-S S S法の時間分割より大きな中間利得を達成する可能性を有しているが、この差は小さいと考えられる。なぜなら、S I-S S S法が直後に続くバーム・ウェルチの再推定処理において状態の再調整を可能にしているためである。従って、結果的には、S I-S S S法による時間方向の分割テストの方が、S S S法の場合より改善されている。

【0118】<6> 本実施形態の不特定話者連続音声認識装置>本実施形態においては、音声認識のための統計的音素モデルセットとしてHMM網11を使用している。当該HMM網11は効率的に表現された音素環境依存モデルである。1つのHMM網は多数の音素環境依存モデルを包含する。HMM網11はガウス分布を含む状態の結合で構成され、個々の音素環境依存モデル間で状態が共有される。このためパラメータ推定のためのデータ数が不足する場合も、頑健なモデルを生成することができる。このHMM網11は、従来例のS S S法から改善されたS I-S S S法を用いて自動生成される。上記S I-S S S法ではHMM網11のトポロジーの決定、異音クラスの決定、各々の状態におけるガウス分布のパラメータの推定

を同時に行なう。本実施形態においては、HMM網11のパラメータとして、ガウス分布で表現される出力確率及び遷移確率を有する。このため認識時には一般的HMMと同様に扱うことができる。さらに、上記HMM網11を用いた、SSS-LR(left-to-right rightmost型)不特定話者連続音声認識装置について説明する。この音声認識装置は、メモリに格納されたHMM網11と呼ばれる音素環境依存型の効率のよいHMMの表現形式を用いている。

【0119】図1において、話者の発聲音声はマイクロホン1に入力されて音声信号に変換された後、特徴抽出部2に入力される。特徴抽出部2は、入力された音声信号をA'D変換した後、例えばLPC分析を実行し、対数パワー、16次ケプストラム係数、△対数パワー及び16次△ケプストラム係数を含む34次元の特徴パラメータを抽出する。抽出された特徴パラメータの時系列はバッファメモリ3を介して音素照合部4に入力される。

【0120】音素照合部4に接続されるHMM網11は、各状態をノードとする複数のネットワークとして表され、各状態はそれぞれ以下の情報を有する。

- (a) 状態番号
- (b) 受理可能なコンテキストクラス
- (c) 先行状態、及び後続状態のリスト
- (d) 出力確率密度分布のパラメータ
- (e) 自己遷移確率及び後続状態への遷移確率

【0121】音素照合部4は、音素コンテキスト依存型LRバーザらからの音素照合要求に応じて音素照合処理を実行する。そして、不特定話者モデルを用いて音素照合区間内のデータに対する尤度が計算され、この尤度の値が音素照合スコアとしてLRバーザらに返される。このときに用いられるモデルは、HMMと等価であるために、尤度の計算には通常のHMMで用いられている前向きパスアルゴリズムをそのまま使用する。

【0122】一方、文脈自由文法データベース20内の所定の文脈自由文法(CFG)を公知の通り自動的に変換してLRテーブル13を生成してそのメモリに格納される。LRバーザらは、上記LRテーブル13を参照して、入力された音素予測データについて左から右方向に、後戻りなしに処理する。構文的にあいまいさがある場合は、スタックを分割してすべての候補の解析が平行して処理される。LRバーザらは、LRテーブル13から次にくる音素を予測して音素予測データを音素照合部4に出力する。これに応答して、音素照合部4は、その音素に対応するHMM網11内の情報を参照して照合し、その尤度を音声認識スコアとしてLRバーザらに戻し、順次音素を連接していくことにより、連続音声の認識を行い、その音声認識結果データを出力する。上記連続音声の認識において、複数の音素が予測された場合は、これらすべての存在をチェックし、ビームサーチの方法により、部分的な音声認識の尤度の高い部分木を残すとい

う枝刈りを行って高速処理を実現する。

【0123】以上の実施形態において、特徴抽出部2と、音素照合部4と、LRバーザ5と、不特定話者モデル生成部31とは、例えばディジタル計算機によって構成される。また、特定話者の発聲音声データ30とHM網11と文脈自由文法データベース20とLRテーブル13とが格納される各メモリとバッファメモリ33とは、例えばハードディスクメモリで構成される。

【0124】

【実施例】

<7. 実験>本実施例では、本実施形態のSI-SSS法の有効性を確立するための事前作業に相当する2つの実験について説明する。実験に使用したコーパスについて説明した後、読み上げ音声に対する話者依存型音声認識の実験結果について述べる。この実験は、SSS法が開発されたときに用いられた典型的な実験であり、極度に制御されたコーパスではSI-SSS法が解決しようとしているタイプの問題が現れないために、SI-SSS法にとっては最も難しいテストとなっている。次いで、我々の目標である話者独立型音声認識により近いタスクにおける利得を実証する予備段階として、多数話者タスクの実験を行った結果について説明する。

【0125】<7. 1 典型的な実験>本発明の目的は、発聲音声としてより良い話者独立型HMMを開発すること、話者独立型音声認識装置の動作において可能な限り最適な性能を獲得すること、及び話者適合化のより良い開始点を提供することである。本発明を発明したときに可能であった発聲音声データ量がバーム・ウェルチの学習アルゴリズムを使用する学習には不十分であったため、我々は実際の読み上げ音声に対して初期話者モデルを学習させ、発聲音声に対してベクトル場平滑化を用いてそのモデルを適合化することに重きを置いた。

【0126】これらの実験には、数種類のコーパス（言語資料）を使用した。話者独立型実験（話者1~2名）における初回のトポロジー学習と、話者依存型実験（話者6名）では、最も使用頻度の高い5240単語（Aセット）からなる分離された単語の読み上げによる日本語コーパスが使用されている。すべての読み上げ音声コーパスは、音素ラベルのシーケンスと、各音声セグメントに対する開始点と終了点とを用いて手書きで書き写されたものであり、このことにより、SSS法の学習を容易にしている。音声は、低ノイズ下でプロの話者により録音された。話者独立型実験では、Aセットで設計されたプロトタイプモデルを、話者独立型読み上げ音声データベース（Cセット：15名の話者が50音素を均等に配置した文章を異なる発話速度で3回発音している。）のサブセット上で再学習させた。Cセットデータの録音には、Aセットデータの場合と同じタイプのマイクロホンを使用した。ポーズ単位（休止単位）は手書きでマークが付けられたが、音素境界にはマークが付与されていない。

い。AセットとCセットコーパスに関しては、従来文献20「A. Kurematsu et al., "ATR Japanese speech database as a tool of speech recognition and synthesis", Speech Communication, 9:357-363, 1990年」において説明されている。最後に、発聲音声コーパスを使用して、音声認識の性能評価を行った（発聲音声コーパスは、例えば、従来文献21「N. Uratani et al., "ATR Integrated Speech and Language Database", ATR Technical Report TR-IT-0056, 1994年」参照。）。このコーパスは、従来文献22「H. Singer et al., "Development testsets and administrative tools for ATR's non-read speech databases (SLDB and SDB)", Technical Report TR-IT-0118, ATR, 1995年」において明記されているように、学習セットとテストセットとに分割した。すべての発聲音声学習データは、日本語話者1名、英語話者1名、及び翻訳者（音声言語パート）2名を含む2言語の会話の集合からなる。データを収集したのは異なる3つの会社であるために、その品質（例えば、SNR（信号雑音比））にはかなりの差がある。使用するのは翻訳者でない話者による音声のみとし、メモリ上の制約から、少数の6秒以上のポーズ単位は学習セットから除外した。

【0127】話者独立型実験に使用する開発テストデータには、発聲音声コーパスの音声言語パート及び音声パートの両方（すなわち、日本語話者2名間の单一言語会話）を使用した。このデータは、こうした発音には埋もれたポーズが多いという点から、より「自然な」ものとなっている。このテストセットには、女性話者4名（会話形文体15、音素9711）と男性話者3名（会話形文体16、音素11231）が含まれている。

【0128】分析パラメータは、サンプリング周波数12000Hz、フレームシフト5ms、フレーム長20ms、ブリエンファシス0, 98, 16次のLPC分析及び16次ケプストラム計算、16次△ケプストラム、パワー値、及び△パワー値であった。△ケプストラム計算用の三角形の回帰窓の長さは、両面とも9フレーム分（すなわち、90msの両面窓）であった。認識実験は、日本語を音素対文法で表現した、音素配列上に制約のあるワンパスビタビアルゴリズムを使用して行った（従来文献23「H. Singer et al., "Speech recognition without grammar or vocabulary constraints", Proceedings

of International Conference on Spoken Language Processing, pp. 2207-2210, 1994年(参照)。

【0129】<7.2 話者依存型HM網実験> S I - S S S法アルゴリズムが、少なくとも常にS S S法アルゴリズムと同等の性能を示すことを証明するため、我々は、初回の実験を話者依存型のモードで行った。200及び400状態数の單一ガウス分布HMMと混合数3の400状態ガウス分布HMMを、各話者毎にAセッタの偶数番単語(2620語)について学習を行った。初回のトポロジーでは26の状態を使用して(図7が示すよ

バーセントアキュラシー

話者	200状態1混合		400状態1混合		400状態3混合	
	SSS	S I - S S S	SSS	S I - S S S	SSS	S I - S S S
MHT	93.9	92.8	95.4	94.5	96.1	96.0
MAU	93.6	93.2	95.2	95.2	96.4	96.7
MXM	91.7	91.9	93.6	93.9	95.3	95.1
FTK	91.5	91.1	92.9	94.0	94.7	95.0
FMS	89.7	91.3	91.9	93.2	94.2	94.6
FYM	90.7		92.4		92.9	
	93.6		95.1		95.5	
平均値	91.9	92.1	93.7	94.1	95.3	95.5

【0131】表1から明らかなように、平均的な場合(大部分がこの場合である)では、本実施形態のS I - S S S法の方が従来例のS S S法より僅かに良い結果を示していることが解る。唯一の例外が話者MHTであり、ほとんどのS S S法の開発作業に使用されたものである。特に、話者がプロでありまた録音が高品質であることから、この話者依存型データの状態分布の不要な分散はコンテキスト方向のものであり、その差は予想通り僅かなものである。

【0132】さらに、特に、状態数200のトポロジーの場合、本実施形態のS I - S S S法は、従来例のS S S法よりも多くの音素にわたって多数の異音を分配(又は分類)することがわかった。S I - S S S法は子音に対してS S S法より多くの異音を分配し、また、母音に関しては異音を幾分より均等に分配している。分配の相違点は、特に、/a/と/u/の対比において顕著であり、S S S法は/u/よりも/a/に関して格段に多くの異音を分配するが、S I - S S S法の場合、状態数400のHMMでは同様の数の異音を有するが、状態数200のHMMでは/u/の方に多くの異音を有している。

【0133】次いで、S S S法及びS I - S S S法のC P Uの計算時間を測定した。計算時間は、S I - S S S

うに、24音素のそれぞれの中心に各1状態と、全音素が共有する形の左右各1状態)、初回のHM網の学習時間を減少させ、また各音素が認識可能となることを保証した。これら複数のHMMは、1310語の奇数番単語についてテストされた。HM網のトポロジー生成後は、最大21の反復のバーム・ウェルチ反復を実行し、單一ガウス分布HMMの状態観測分布を推定した。單一ガウス分布HMMの場合、相対的な尤度利得に関するしきい値テストを用いて、通常10回未満の反復を必要とする。この実験結果は表1の通りである。

【0130】

【表1】

法の方がS S S法より格段に短かった。これは、S I - S S S法の場合、時間方向の分割の方がコスト高であることから、特に可能性のあるすべての時間方向の分割が選択された後にこれが顕著である。シーケンス内の最大状態数が、最小の音素持続時間の制約条件である20msを有効に確立させるために、4に制限されているため、ここでは、時間方向分割数が限定されている。

【0134】図8は、話者FTKに関するC P Uの計算時間の差を図示したものである。一方、本実施形態のS I - S S S法は、分割に使用するためバーム・ウェルチの状態尤度を格納しなくてはならず、S S S法より以上の記憶装置を必要とする。2620単語の学習セットでは、そのコストの差はおよそ、80MBに対して50MBである。話者10名であって、話者1名当たり1000語の話者独立型学習は、100MBの主記憶装置を使用し、パラメータファイルをディスクへスワップすることによって実行されるものと推定される。

【0135】<7.3 複数話者HM網実験> 次に、図1の連続音声認識装置を用いて、複数話者の音声認識実験を行い、従来例のS S S法と本実施形態のS I - S S S法を比較した。6名の話者(MAU、MHT、MXM、FYM、FMS、FTK)の各人に關し、5240語のデータベースの偶数番単語から500語をランダム

に選択した（データベースについては、従来技術20参照。）。選択されたデータは、総計で3000語となり、話者依存型の各実験に使用したものとほぼ同数である。複数話者のHMM又は話者依存型HMMの場合、明らかにより多量の学習データが必要であるが、当実験の目的は主として、デバックングのためであった。HM網の生成処理は、話者依存実験の場合と同じ処理を使用した。すなわちHMMを、状態数200の場合は單一ガウス（混合数1）分布で、また状態数400では混合数1及び3で保持した。音声認識に際しては、話者6名の各人に付きランダムに選んだ100語を使用して、複数話者モードでテストした。

【0136】図9にその結果を示す。図9から明らかなように、本実施形態のS I - S S S法は、一貫して従来例のS S S法より良い結果を示している。その差が最も大きいのは、單一（混合数1）の混合ガウス分布を用いたより高いコンテキスト方向の分解度を有するHMM（状態数400）の場合である。混合数3を使用する場合はこの差が小さくなるが、このことは驚くことではない。なぜならば、混合数を複数にすることによって、異音の欠落を補償することができるためである。

【0137】

【発明の効果】以上詳述したように本発明に係る請求項1記載の不特定話者モデル生成装置によれば、複数の特定話者の発聲音声データに基づいて話者独立型の隠れマルコフモデルを生成するモデル生成手段を備えた不特定話者モデル生成装置において、上記モデル生成手段は、複数の特定話者の発聲音声データに基づいて、バーム・ウェルチの学習アルゴリズムを用いて單一ガウス分布の隠れマルコフモデルを生成した後、上記單一ガウス分布の隠れマルコフモデルにおいて、1つの状態をコンテキスト方向又は時間方向に分割したときに、最大の尤度の増加量を有する状態を分割することを繰り返すことにより話者独立型の隠れマルコフモデルを生成する。従って、多数の話者の膨大な学習用テキストデータを必要とせず、従来例に比較して処理装置のメモリ容量の少なくてすみ、その計算時間を短縮することができる。

【0138】また、請求項2記載の不特定話者モデル生成装置においては、請求項1記載の不特定話者モデル生成装置において、上記モデル生成手段は、複数の特定話者の発聲音声データに基づいて、バーム・ウェルチの学習アルゴリズムを用いて單一ガウス分布の隠れマルコフモデルを生成する初期モデル生成手段と、上記初期モデル生成手段によって生成された單一ガウス分布の隠れマルコフモデルにおいて、1つの状態をコンテキスト方向又は時間方向に分割したときに、最大の尤度の増加量を有する状態を検索する検索手段と、上記検索手段によって検索された最大の尤度の増加量を有する状態を、最大の尤度の増加量に対応するコンテキスト方向又は時間方向に分割した後、バーム・ウェルチの学習アルゴリズム

を用いて單一ガウス分布の隠れマルコフモデルを生成する生成手段と、上記生成手段の処理と上記検索手段の処理を、單一ガウス分布の隠れマルコフモデル内の状態を分割することができなくなるまで又は又は單一ガウス分布の隠れマルコフモデル内の状態数が予め決められた分割数となるまで繰り返すことにより、話者独立型の隠れマルコフモデルを生成する制御手段とを備える。従って、多数の話者の膨大な学習用テキストデータを必要とせず、従来例に比較して処理装置のメモリ容量の少なくてすみ、その計算時間を短縮することができる。

【0139】さらに、請求項3記載の不特定話者モデル生成装置においては、請求項2記載の不特定話者モデル生成装置において、上記検索手段によって検索される状態は、直前の処理で上記生成手段によって分割された新しい2つの状態に限定される。これによって、請求項1又は2記載の装置に比較して処理装置の計算時間を短縮することができる。

【0140】さらに、請求項4記載の不特定話者モデル生成装置においては、請求項2記載の不特定話者モデル生成装置において、上記検索手段によって検索される状態は、直前の処理で上記生成手段によって分割された新しい2つの状態と、上記新しい2つの状態から距離が1だけ離れた状態とに限定される。これによって、請求項1、2又は3記載の装置に比較して処理装置の計算時間を短縮することができる。

【0141】またさらに、請求項5記載の音声認識装置においては、入力される発聲音声文の音声信号に基づいて所定の隠れマルコフモデルを参照して音声認識する音声認識手段を備えた音声認識装置において、上記音声認識手段は、請求項1乃至4のうちの1つに記載の不特定話者モデル生成装置によって生成された話者独立型の隠れマルコフモデルを参照して音声認識する。従って、生成された不特定話者モデルを参照して音声認識することができ、従来例に比較して音声認識率を改善することができる音声認識装置を提供することができる。

【図面の簡単な説明】

【図1】 本発明に係る一実施形態である音声認識装置のブロック図である。

【図2】 図1の不特定話者モデル生成部31によって実行されるS I - S S S法の話者モデル生成処理を示すフローチャートである。

【図3】 図2のステップS 15で用いる最尤分割設定処理のサブルーチンを示すフローチャートである。

【図4】 従来例及び実施形態における状態分割を示すHM網の一例の状態遷移図であって、(a)は元のHM網であり、(b)はコンテキスト方向の分割を示すHM網であり、(c)は時間方向の分割を示すHM網である。

【図5】 図2のS I - S S S法の話者モデル生成処理によって実行される時間方向の分割を示す状態遷移図で

ある。

【図6】 図2のSI-SSS法の話者モデル生成処理によって実行される時間方向の分割のために、数52及び数53を用いてパラメータ α_{ht} (q)及び β_{ht} (q, q')を計算するときに用いるデータ及び状態を示す図である。

【図7】 話者依存型実験のための初期HM網のトポロジーを示す状態遷移図である。

【図8】 図2のSI-SSS法の話者モデル生成処理と図13のSSS法の話者モデル生成処理に対するCPU時間の比較を示すグラフである。

【図9】 図1の音声認識装置を用いたときの、複数の話者認識タスクに対する図2のSI-SSS法の話者モデル生成処理と図13のSSS法の話者モデル生成処理の音素認識率を示すグラフである。

【図10】 従来例のHM網の構造を示す状態遷移図である。

【図11】 従来例のHM網で表現される各異音モデル構造を示す状態遷移図である。

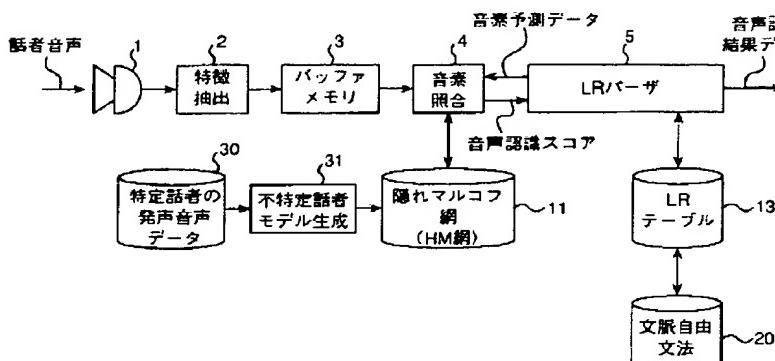
【図12】 従来例のSSS法の話者モデル生成処理の原理を示す図である。

【図13】 従来例のSSS法の話者モデル生成処理を示すフローチャートである。

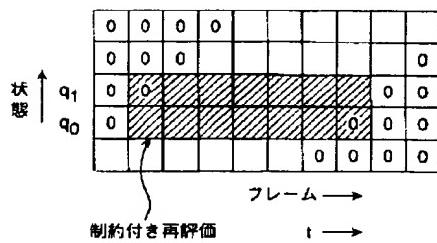
【符号の説明】

- 1…マイクロホン、
- 2…特徴抽出部、
- 3…バッファメモリ、
- 4…音素照合部、
- 5…LRバーザ、
- 11…隠れマルコフ網(HM網)、
- 13…LRテーブル、
- 20…文脈自由文法データベース、
- 30…特定話者の発声音声データ、
- 31…不特定話者モデル生成、

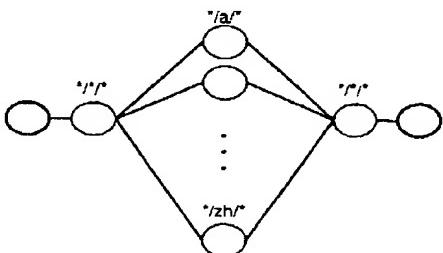
【図1】



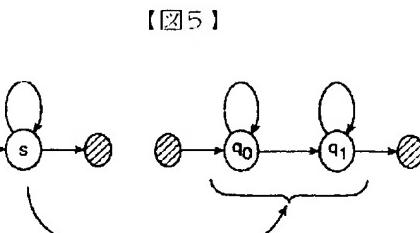
【図6】



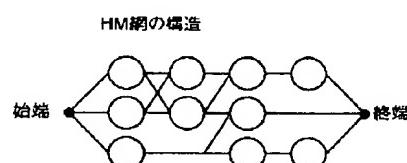
【図11】



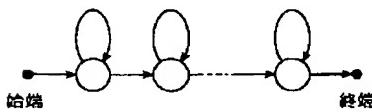
【図7】



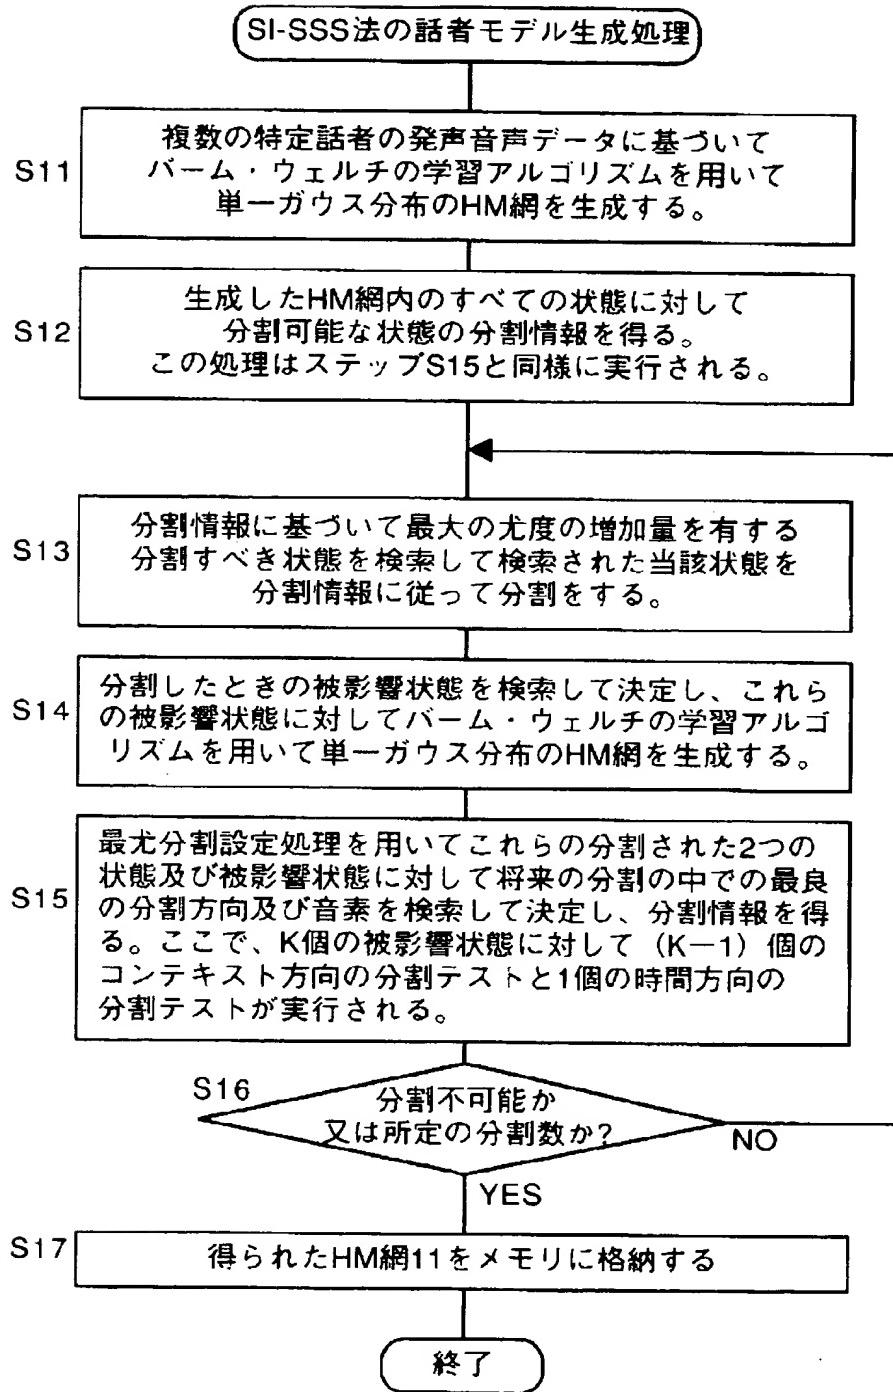
【図10】



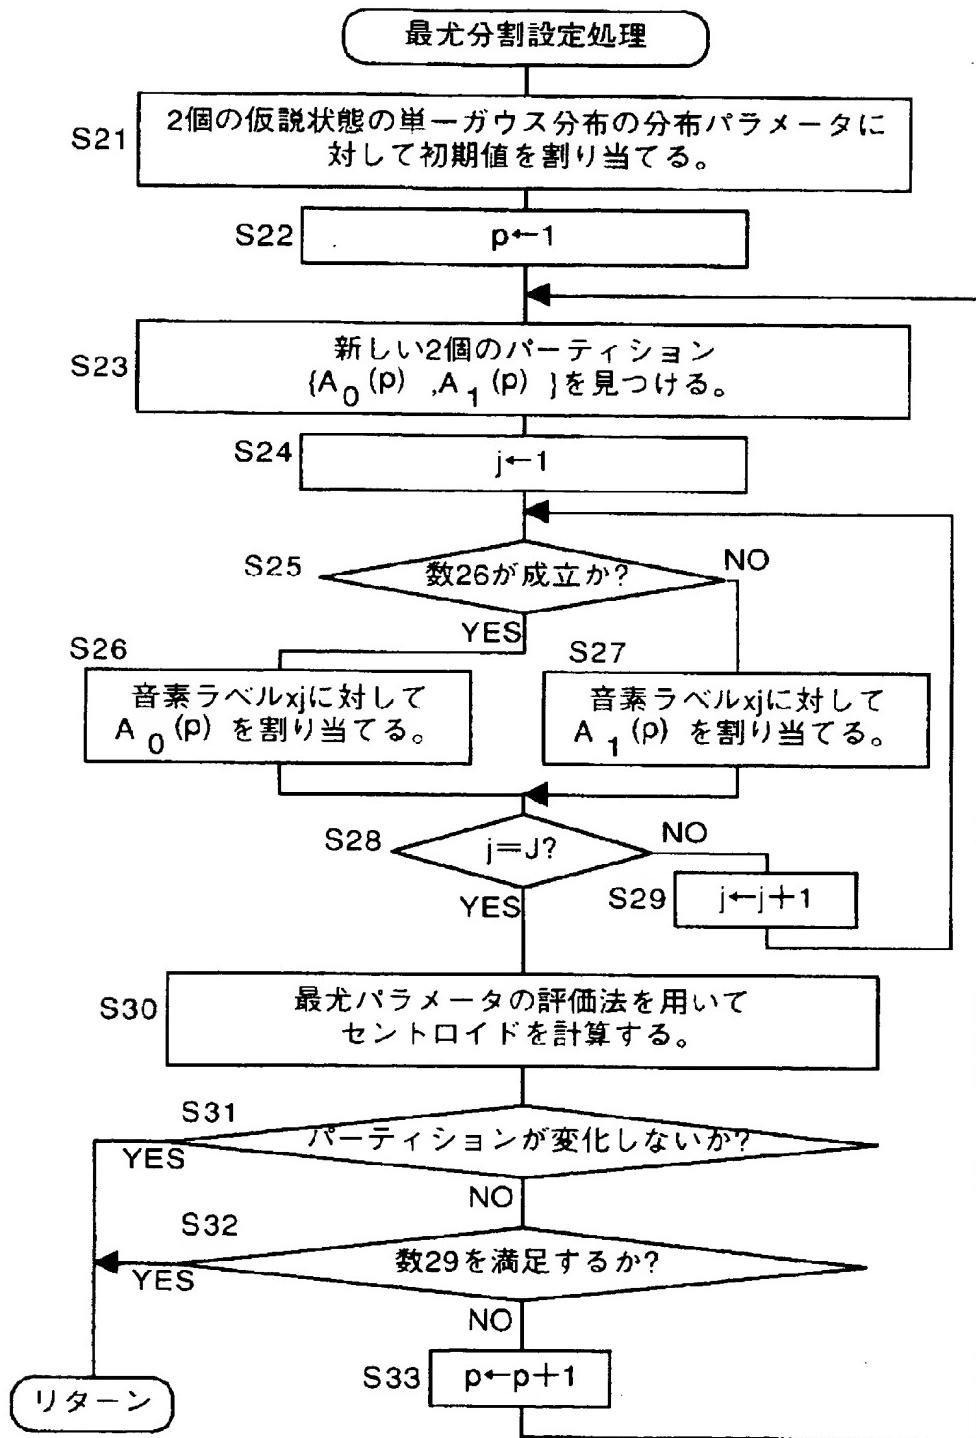
HM網で表現される各異音モデルの構造



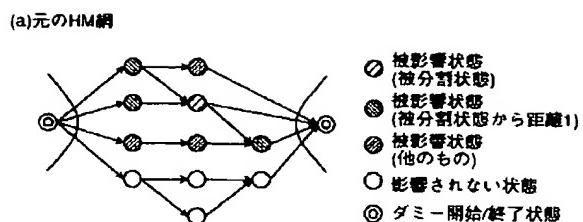
【図2】



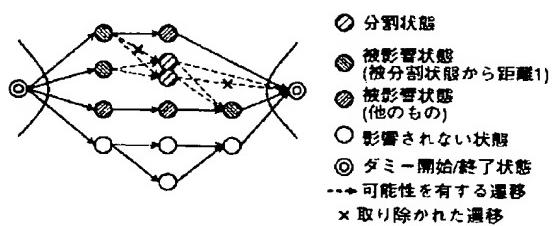
【図3】



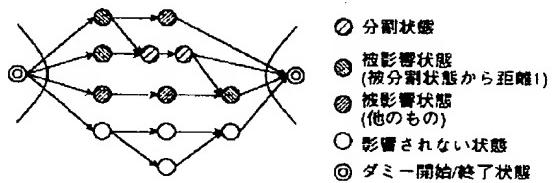
【図4】



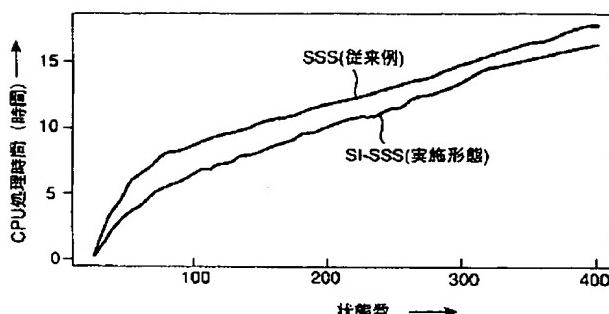
(b)コンテキスト方向の分割



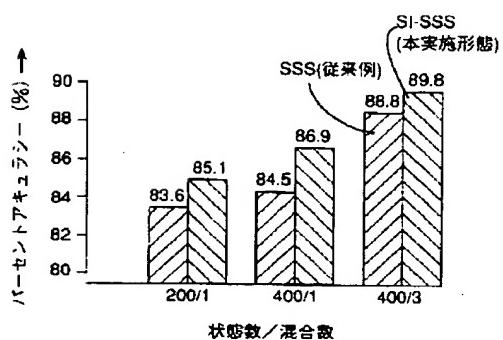
(c)時間方向の分割



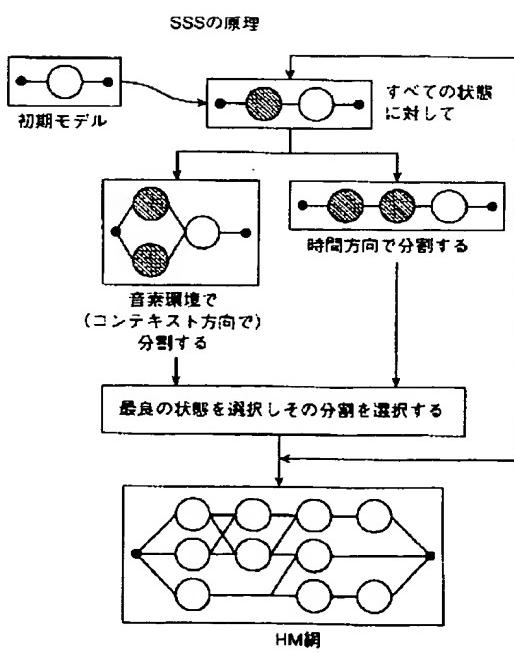
【図8】



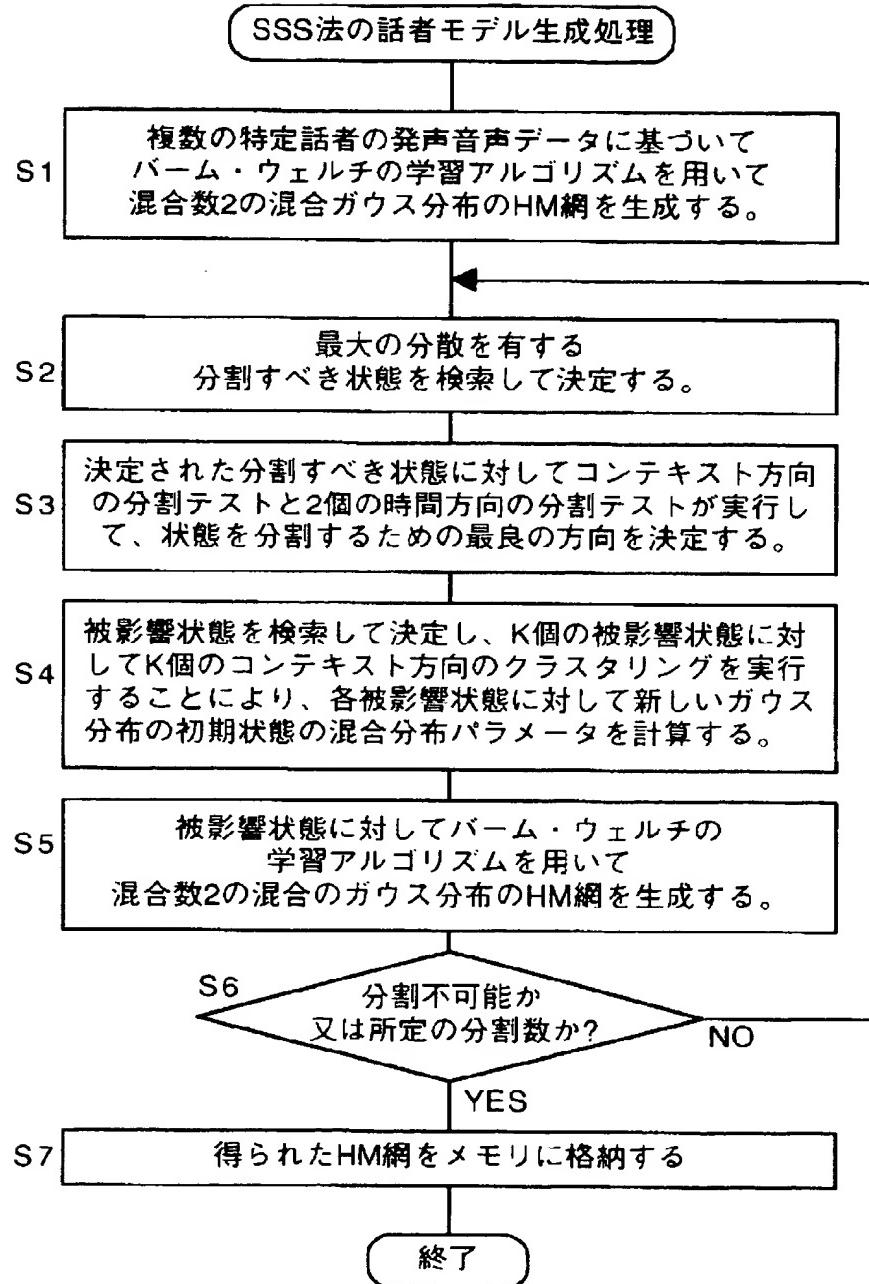
【図9】



【図12】



【図13】



**This Page is Inserted by IFW Indexing and Scanning
Operations and is not part of the Official Record**

BEST AVAILABLE IMAGES

Defective images within this document are accurate representations of the original documents submitted by the applicant.

Defects in the images include but are not limited to the items checked:

- BLACK BORDERS**
- IMAGE CUT OFF AT TOP, BOTTOM OR SIDES**
- FADED TEXT OR DRAWING**
- BLURRED OR ILLEGIBLE TEXT OR DRAWING**
- SKEWED/SLANTED IMAGES**
- COLOR OR BLACK AND WHITE PHOTOGRAPHS**
 - GRAY SCALE DOCUMENTS**
- LINES OR MARKS ON ORIGINAL DOCUMENT**
- REFERENCE(S) OR EXHIBIT(S) SUBMITTED ARE POOR QUALITY**
- OTHER:** _____

IMAGES ARE BEST AVAILABLE COPY.

As rescanning these documents will not correct the image problems checked, please do not report these problems to the IFW Image Problem Mailbox.

THIS PAGE BLANK (USPTO)